



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

Martin Surjak

**VALIDACIJA NUMERIČKIH MODELA
MEHANIČKOGA PONAŠANJA ŽIVOTINJSKIH I
LJUDSKIH KOSTIJU**

DOKTORSKI RAD

Zagreb, 2015.



UNIVERSITY OF ZAGREB
FACULTY OF MECHANICAL ENGINEERING AND NAVAL ARCHITECTURE

Martin Surjak

**VALIDATION OF NUMERICAL MODELS OF
MECHANICAL BEHAVIOR OF ANIMAL AND HUMAN
BONES**

DOCTORAL THESIS

Zagreb, 2015.



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

Martin Surjak

**VALIDACIJA NUMERIČKIH MODELA
MEHANIČKOGA PONAŠANJA ŽIVOTINJSKIH I
LJUDSKIH KOSTIJU**

DOKTORSKI RAD

Mentori:

dr. sc. Janoš Kodvanj, redoviti profesor

dr. sc. Dragica Bobinac, redoviti profesor

Zagreb, 2015.



UNIVERSITY OF ZAGREB
FACULTY OF MECHANICAL ENGINEERING AND NAVAL ARCHITECTURE

Martin Surjak

**VALIDATION OF NUMERICAL MODELS OF
MECHANICAL BEHAVIOR OF ANIMAL AND HUMAN
BONES**

DOCTORAL THESIS

Supervisors:

Dr. sc. Janoš Kodvanj, Professor

Dr. sc. Dragica Bobinac, Professor

Zagreb, 2015.

Podaci za bibliografsku karticu

UDK: 519.6 : 612.75 : 502.087

Ključne riječi: računalna tomografija, mjerenje polja pomaka, gustoća kosti, modul elastičnosti, biomehanika

Znanstveno područje: tehničke znanosti

Znanstveno polje: strojarstvo

Institucija u kojoj je rad izrađen: Fakultet strojarstva i brodogradnje Sveučilišta u Zagrebu

Mentori rada: prof. dr. sc. Janoš Kodvanj
prof. dr. sc. Dragica Bobinac

Broj stranica: 121

Broj slika: 106

Broj tablica: 15

Broj korištenih bibliografskih jedinica: 96

Datum obrane: 22. prosinca 2015.

Povjerenstvo: prof. dr. sc. Zdenko Tonković, Fakultet strojarstva i brodogradnje, Zagreb
prof. dr. sc. Janoš Kodvanj, Fakultet strojarstva i brodogradnje, Zagreb
prof. dr. sc. Dragica Bobinac, Medicinski fakultet, Rijeka
prof. dr. sc. Tanja Jurčević Lulić, Fakultet strojarstva i brodogradnje, Zagreb
dr. sc. Nikica Daraboš, Klinika za traumatologiju KBC-a Sestre milosrdnice,
Zagreb

Institucija u kojoj je rad pohranjen: Fakultet strojarstva i brodogradnje Sveučilišta u Zagrebu

Zahvala

Ponajprije, izražavam veliku zahvalnost svojem mentoru prof. dr. sc. Janošu Kodvanju jer mi je omogućio bavljenje ovim vrlo zanimljivim i iznimno aktualnim područjem. Hvala mu i na savjetima, na pruženoj potpori i vodstvu te na strpljenju tijekom izrade ove disertacije. Također, velika hvala mojoj mentorici prof. dr. sc. Dragici Bobinac zato što nam je osigurala ispitne uzorke te svojim savjetima, uputama i dobrom voljom dala medicinsku podlogu koja je poboljšala kvalitetu ove doktorske disertacije.

Zahvaljujem i članovima povjerenstva prof. dr. sc. Zdenku Tonkoviću, prof. dr. sc. Tanji Jurčević Lulić te dr. sc. Nikici Darabošu jer su svojim pažljivim čitanjem i primjedbama također poboljšali kvalitetu ove disertacije.

Velika hvala prof. dr. sc. Draženu Vnuku i asistentu Petru Kostešiću, dr. med. vet. s Veterinarskog fakulteta Sveučilišta u Zagrebu zato što su osigurali ispitne uzorke ovčjih kostiju. Zahvaljujem i prof. dr. sc. Slavku Davili koji je osigurao ispitne uzorke svinjskih kostiju. Veliku zahvalu također upućujem doc. dr. sc. Vinku Vidjaku i Krunoslavu Marinčeviću, bacc. med. radiol. iz Kliničkoga zavoda za dijagnostičku intervencijsku radiologiju KB-a Merkur Zagreb, na pruženoj potpori i pomoći tijekom CT-snimanja ispitnih uzoraka.

Zahvaljujem svim djelatnicima Laboratorija za eksperimentalnu mehaniku te bivšem djelatniku dr. sc. Anti Bakiću na stručnim, znanstvenim i životnim savjetima koji su mi rad u laboratoriju učinili ugodnim.

Na kraju zahvaljujem svojoj obitelji, a posebno supruzi Martini i kćeri Klari jer su cijelo vrijeme bile uz mene i pružale mi dodatnu motivaciju za izradu ove doktorske disertacije.

Zagreb, prosinac 2015.

Martin Surjak

Sadržaj

Sažetak.....	I
Summary	II
Popis slika.....	III
Popis tablica	VIII
Popis važnijih oznaka.....	IX
1. UVOD	1
1.1. Motivacija.....	1
1.2. Pregled dosadašnjih istraživanja	2
1.3. Ciljevi i hipoteze istraživanja	7
1.4. Očekivani znanstveni doprinos	8
1.5. Struktura rada	8
2. KOST I KOŠTANO TKIVO	11
2.1. Građa kosti	11
2.1.1. Kortikalna kost.....	12
2.1.2. Trabekularna kost.....	13
2.2. Bedrena kost.....	14
2.3. Prijelomi bedrene kosti.....	15
3. MJERENJE POMAKA I DEFORMACIJA	16
3.1. Vertikalni hod kicalice	16
3.2. Mehanički ekstenzometar.....	17
3.3. Laserski ekstenzometar	18
3.4. Videoekstenzometar	18
3.5. Elektrootporne mjerne trake.....	19

3.6.	Korelacija digitalne slike.....	20
3.7.	Mjerenje optičkim sustavom <i>Aramis</i>	24
3.7.1.	Nanošenje stohastičkog uzorka na površinu	25
3.7.2.	Podešavanje i kalibracija sustava.....	25
3.7.3.	Provedba snimanja uzoraka	27
3.7.4.	Pohrana i obrada digitalnih slika.....	28
4.	EKSPERIMENTALNO ISPITIVANJE.....	32
4.1.	Savijanje svinjskih femura u tri točke	32
4.2.	Tlačno ispitivanje femura.....	34
4.2.1.	Ispitivanje svinjskih femura	34
4.2.1.1	Priprema uzoraka	34
4.2.1.2	Provedba mehaničkog ispitivanja	37
4.2.1.3	Mjerenje pomaka i deformacija na površini kosti.....	42
4.2.2.	Ispitivanje ovčjih femura	43
4.2.3.	Ispitivanje kadaveričnih femura.....	46
5.	RAČUNALNA TOMOGRAFIJA	49
5.1.	Princip računalne tomografije	49
5.2.	Hounsfieldov broj.....	52
5.3.	Artefakti	53
5.4.	Određivanje gustoće kosti	55
5.4.1.	Dvoenergijska rendgenska denzitometrija (DEXA)	56
5.4.2.	Određivanje gustoće kostiju računalnom tomografijom.....	56
5.4.2.1	Radiološka gustoća kosti.....	56
5.4.2.2	Gustoća koštanog pepela.....	57
5.4.2.3	Prividna gustoća kosti	58
6.	NUMERIČKI MODEL BAZIRAN NA RAČUNALNOJ TOMOGRAFIJI.....	60
6.1.	Provedba CT skeniranja kosti	60
6.2.	Rekonstrukcija geometrije.....	61
6.3.	Mreža konačnih elemenata.....	63
6.4.	Materijalni model	67

6.4.1. Nehomogeni numerički model kosti	68
6.4.1.1 Povezivanje Hounsfieldova broja s gustoćom kosti.....	68
6.4.1.2 Povezivanje gustoće kosti i modula elastičnosti	72
6.4.1.3 Preslikavanje parametara materijala na mrežu konačnih elemenata	75
6.5. Opterećenje i rubni uvjeti	80
7. REZULTATI.....	82
7.1. Rezultati savijanja svinjskih femura u tri točke	82
7.2. Rezultati tlačnog ispitivanja femura.....	85
7.2.1. Svinjski femur	85
7.2.2. Ovčji femur	94
7.2.3. Kadaverični femur	101
8. ZAKLJUČAK	108
8.1. Znanstveni doprinos	110
8.2. Buduća istraživanja	111
LITERATURA	112
Životopis	120
Curriculum vitae	121

Sažetak

Primjena metode konačnih elemenata postaje nezaobilazna u biomehanici i medicini, osobito pri numeričkom modeliranju kosti ili sustava kost – implantat. Budući da je koštano tkivo nehomogen materijal, primjena računalne tomografije (engl. *Computed Tomography* – CT) vrlo je važna u razvoju numeričkih modela kostiju. Na osnovi CT-a može se vrlo precizno rekonstruirati geometrija kosti i odrediti gustoća svakoga pojedinog voksel. Gustoća kosti povezana je s modulom elastičnosti, no ta veza nije jednaka za svaku kost. U ovom istraživanju kost je na razini konačnog elementa modelirana kao linearno elastičan materijal s izotropnim svojstvima, dok u mreži konačnih elemenata modul elastičnosti varira s gustoćom kosti tako da je cijela kost modelirana kao nehomogeni materijal. Pravilan odabir relacije koja povezuje gustoću i modul elastičnosti znatno utječe na rezultate računalnih simulacija, stoga je potrebno validirati numeričke modele eksperimentalnim *in vitro* ispitivanjem svježih kostiju. Danas se u biomehaničkim istraživanjima, ponajprije jer se lakše nabavljaju, često koristimo životinjskim kostima. Konkretno, svinjske i ovčje kosti zbog svoje su građe, oblika i dimenzija prikladne za testiranje medicinskih implantata namijenjenih ljudima. Većina relacija gustoća – modul elastičnosti dostupnih u literaturi, ograničena je na ljudski femur (bedrena kost) te je upitna njihova primjenjivost na ostale ljudske ili životinjske kosti.

Cilj predloženoga doktorskog rada jest *in vitro* eksperimentalno ispitivanje svježih životinjskih i ljudskih kostiju primjenom metode korelacije digitalne slike (engl. *Digital image correlation* – DIC) za mjerenje pomaka i deformacija. Metoda korelacije digitalne slike suvremena je beskontaktna metoda koja omogućuje mjerenje cijelog polja pomaka na površini mjernog objekta i sve se češće primjenjuje za ispitivanje bioloških tkiva. S obzirom na to da daje kao rezultat cijelo polje pomaka i deformacija, metoda je kvalitetan alat za validaciju numeričkih modela kostiju. Spomenuta metoda omogućuje bolji uvid u mehaničko ponašanje kosti te realnije prikazuje njezin mehanički odziv na narinuto opterećenje. Predloženo istraživanje obuhvaća numeričko modeliranje kosti na temelju računalne tomografije, te na osnovi usporedbe s eksperimentom, definiranje relacija gustoća – modul elastičnosti za pojedine vrste kostiju. Za veći dio istraživanja korištene su svježe svinjske i ovčje kosti, uglavnom zbog njihove pristupačnosti.

Ključne riječi: računalna tomografija, mjerenje polja pomaka, gustoća kosti, modul elastičnosti, biomehanika

Summary

The finite element method has become an indispensable tool in biomechanics and medicine, especially when the bone or the bone-implant system are modeled numerically. Since the bone tissue material is inhomogeneous, the application of computed tomography (CT) plays a major role in the development of numerical bone models. Based on the CT scan the bone geometry can be precisely reconstructed and the density of each voxel can be determined. The bone density is related to the modulus of elasticity, whereby this relation is not the same for each bone. In this research the bone is at the finite element level modeled as a linear elastic material with isotropic properties. In finite element mesh the modulus of elasticity varies with the bone density so the global bone model was modeled as inhomogeneous material. The proper choice of relation between density and modulus of elasticity of the bone has a big impact on the numerical simulation results, therefore it is necessary to validate numerical models with the experimental in vitro testing of fresh bones. In today's biomechanical investigations, animal bones are often used, mostly because of their availability. In particular, swine and sheep bones are, due to their structure, shape and dimensions, suitable for testing medical implants intended for humans. Most of density-elasticity relations in the literature are limited to the human femur, and their applicability to other human or animal bones is questionable. The aim of this doctoral thesis is in vitro experimental testing of fresh animal and human bones using the digital image correlation (DIC) method for the displacement and strain measurement. The DIC method is a modern non-contact method that enables measurement of displacement fields on the surface of a measured object and has been increasingly used in the biological tissue testing. Since as a result the method produces the displacement and strain field, it represents a quality tool for the validation of numerical models of bones. The mentioned method will give a better insight into the mechanical behavior of bones and show the mechanical response of bone to the applied load in a more realistic manner. The proposed investigation involves numerical modeling of the bone based on computed tomography and a comparison with experimental results, as well as defining the relations between density and modulus of elasticity for certain types of bones. The greater part of the investigation will be carried out on fresh swine and sheep bones primarily because of their accessibility.

Keywords: computed tomography, displacement field measurement, bone density, modulus of elasticity, biomechanics

Popis slika

Slika 1.	Hijerarhijska struktura koštanog tkiva na primjeru ljudske bedrene kosti [79].....	11
Slika 2.	Mikroskopska struktura kortikalnoga koštanog tkiva: a) skica kortikalne kosti, b) presjek kroz Haversov sustav, c) fotomikrografski prikaz Haversova sustava [81]	12
Slika 3.	Prikaz kortikalne i trabekularne kosti	13
Slika 4.	Građa femura.....	14
Slika 5.	Najčešći prijelomi femura: a) intertrohanterni, b) subtrohanterni, c) prijelom vrata	15
Slika 6.	a) Primjer vlačnog teksta; b) Primjer savijanja u tri točke.....	16
Slika 7.	Mjerenje mehaničkim ekstenzometrom	17
Slika 8.	Mjerenje laserskim ekstenzometrom	18
Slika 9.	Mjerenje videoekstenzometrom	19
Slika 10.	Mjerenje deformacija elektrootpornim trakama na svježoj kosti [83]	20
Slika 11.	Shematski prikaz 3D mjerenja s dvije kamere primjenom korelacije digitalne slike	21
Slika 12.	Primjer stohastičkog rastera i crveno označena pravokutna faseta u referentnoj konfiguraciji a) i deformiranoj konfiguraciji b)	21
Slika 13.	Referentna i deformirana konfiguracija	22
Slika 14.	Optički mjerni sustav <i>Aramis</i> [86]	24
Slika 15.	Primjeri stohastičkih uzoraka za različite mjerne volumene [86].....	25
Slika 16.	Kalibracijski objekti [86]	26
Slika 17.	Ilustracija sustava <i>Aramis</i> s potrebnim parametrima za podešavanje	27
Slika 18.	Faseta veličine 15x15, s dva preklapajuća piksela [87]	28
Slika 19.	Ovisnost mjerne nesigurnosti pomaka i deformacija o veličini fasete [85]	28
Slika 20.	Prikaz faseta tijekom nekoliko koraka opterećenja za slučaj 3D mjerenja [87]	30
Slika 21.	Primjer izmjerenih deformacija u nekoliko faza vlačnog ispitivanja aluminijske epruvete [88].....	31
Slika 22.	Eksperimentalni postav za savijanje svinjskih femura u tri točke	32
Slika 23.	Dijagram sila – pomak dobiven savijanjem svinjskog femura u tri točke	33
Slika 24.	Svinjski proksimalni dio femura očišćen od mekog tkiva	35

Slika 25.	Pozicioniranje svinjskog femura specijalnom napravom: a) postavljanje distalnog kraja kosti u cijev, b) fiksiranje distalnog kraja kosti s pomoću polimetilmetakrilata (PMMA).....	35
Slika 26.	Nanošenje stohastičkog uzorka: a) bijela boja, b) crne točkice	36
Slika 27.	Pozicioniranje ispitnog uzorka posebnom napravom za podešavanje: a) naprava za podešavanje na kidalici, b) detalj prihvata ispitnog uzorka	37
Slika 28.	Oštećenje glave femura	38
Slika 29.	Eksperimentalni postav: a) optički sustav <i>Aramis</i> i pozicionirani ispitni uzorak, b) uvećani detalj ispitnog uzorka i adaptera za prijenos opterećenja s aksijalnim ležajem.....	39
Slika 30.	Položaj svinjskog femura tijekom ispitivanja	39
Slika 31.	Dijagram sila – pomak dobiven opterećivanjem svinjskog femura	40
Slika 32.	Dijagram sila – pomak dobiven opterećivanjem svinjskih femura.....	41
Slika 33.	Kalibracija optičkog sustav <i>Aramis</i>	42
Slika 34.	Referentna (nedeformirana) slika uzorka SF1 s jedne od kamera: a) odabrana veličina faseta, b) referentna slika bez polja faseta, c) referentna slika s poljem faseta.....	43
Slika 35.	Priprema ovčjeg femura za mehaničko ispitivanje	44
Slika 36.	Ovčji femur pozicioniran na kidalici	44
Slika 37.	Dijagram sila – pomak ovčjeg femura za različite brzine opterećivanja	45
Slika 38.	Dijagram sila – pomak za ovčje femure.....	45
Slika 39.	Ispitni uzorak kadaveričnog femura pripremljen za mehaničko ispitivanje	46
Slika 40.	Dijagram sila – pomak dobiven opterećivanjem kadaveričnih femura.....	47
Slika 41.	Lom ispitnog uzorka KF2	48
Slika 42.	CT-uređaj Toshiba Aquilion [90]	49
Slika 43.	Princip rada CT-uređaja [91]	50
Slika 44.	a) Klasični CT-uređaj b) MSCT-uređaj	51
Slika 45.	Pikaz CT-sloja koji se sastoji od anizotropnih voksela.....	52
Slika 46.	Artefakti na CT-snimici osobe koja ima ugrađen umjetni kuk	54
Slika 47.	Primjer CT-snimke s artefaktom a) i s uklonjenim artefaktom b) [94]	54
Slika 48.	Primjeri kalibracijskih fantoma u kojima se nalaze mediji ekvivalentni koštano tkivu. a) B-MAS 200 (Kyoto-Kagaku Co. Ltd., Kyoto, Japan), b) QRM-EDP fantom (QRM GmbH Njemačka) i c) QRM-BDC fantom (QRM GmbH Njemačka)	57

Slika 49.	Primjer dijagrama koji pokazuje vezu između volumetrijske mineralne gustoće kosti i Hounsfieldova broja [50].....	57
Slika 50.	Skeniranje ovčjeg femura na MSCT-uređaju Toshiba Aquilion.....	60
Slika 51.	CT-snimka svinjskog femura i raspodjela Hounsfieldova broja na kortikalnom i trabekularnom dijelu kosti.....	62
Slika 52.	Postupak generiranja 3D modela: a) određivanje maske na jednom od slojeva b) filtriranje neželjenih okolnih piksela i definiranje rubova, c) 3D model	63
Slika 53.	Mreža heksaedarskih konačnih elemenata dobivena direktnim pretvaranjem vokselu u konačne elemente (<i>Voxel based mesh</i>) na primjeru svinjskog femura..	64
Slika 54.	Mreža konačnih elemenata dobivena umrežavanjem CAD modela svinjskog femura.....	65
Slika 55.	Konvergenција pomaka za model svinjske kosti	66
Slika 56.	Konvergenција pomaka za model ovčje kosti.....	66
Slika 57.	Konvergenција pomaka za model kadaverične kosti	67
Slika 58.	Provedba CT-skeniranja ovčjeg femura zajedno s kalibracijskim fantomom za gustoću kosti	68
Slika 59.	Kalibracijski fantom za gustoću kosti B-MAS 200 (Kyoto-Kagaku Co. Ltd., Kyoto, Japan).....	69
Slika 60.	Mjerenje srednje vrijednosti Hounsfieldova broja na CT-snimci	69
Slika 61.	Veza volumetrijske mineralne gustoće kosti i Hounsfieldova broja za svinjski femur	70
Slika 62.	Relacije gustoća – modul elastičnosti često korištene u literaturi [46].....	73
Slika 63.	Grafički prikaz izraza (13), (15) i (18).....	74
Slika 64.	Grafički prikaz izraza (14), (16) i (17).....	74
Slika 65.	CT-snimke femura ovce: a) klasični prikaz jednog od CT-slojeva, b) prikaz CT-sloja zajedno s mrežom konačnih elemenata, c) vokseli unutar jednog konačnog elementa.....	76
Slika 66.	Podjele Hounsfieldove skale na konačan broj segmenata kod modela svinjskoga proksimalnog femura.....	77
Slika 67.	Dijagram ovisnosti maksimalnog pomaka o stupnju homogenizacije kod modela svinjskog femura	78
Slika 68.	Dijagram ovisnosti maksimalne deformacije o stupnju homogenizacije kod modela svinjskog femura.....	78

Slika 69.	Raspodjela Hounsfieldova broja kod modela svinjskog proksimalnog femura za stupanj homogenizacije 40	79
Slika 70.	Numerički model svinjskog femura: a) pozicioniranje modela kosti, b) dodjeljivanje opterećenja i rubnih uvjeta	80
Slika 71.	Dijagram sila – pomak svježih ne zamrzavanih svinjskih femura.....	82
Slika 72.	Dijagram sila – pomak odmrznutih svinjskih femura	84
Slika 73.	Pomaci i deformacije određeni korelacijom digitalne slike pri sili od 1,5 kN: a) polje pomaka na površini uzorka SF2, b) raspodjela deformacija na površini uzorka SF2.....	86
Slika 74.	Pomaci i deformacije određeni metodom konačnih elemenata pri sili od 1,5 kN: a) polje pomaka (u mm) na modelu SF2, b) raspodjela deformacija na modelu SF2.....	86
Slika 76.	Pomaci duž presjeka na ispitnom uzorku SF2 pri sili od 1,5 kN	88
Slika 77.	Deformacije duž presjeka na ispitnom uzorku SF2 pri sili od 1,5 kN	88
Slika 78.	Pomaci duž presjeka na ispitnom uzorku SF2 pri sili od 3 kN	89
Slika 79.	Deformacije duž presjeka na ispitnom uzorku SF2 pri sili od 3 kN	89
Slika 80.	Maksimalne deformacije po presjeku svinjskih femura pri sili od 1,5 kN	90
Slika 81.	Maksimalni pomaci po presjeku svinjskih femura pri sili od 1,5 kN	91
Slika 82.	Maksimalne deformacije po presjeku svinjskih femura pri sili od 3 kN	91
Slika 83.	Maksimalni pomaci po presjeku svinjskih femura pri sili od 3 kN	92
Slika 84.	Prosječna relativna pogreška maksimalnih deformacija svih pet uzoraka svinjskih femura pri sili od 1,5 kN i 3 kN	93
Slika 85.	Pomaci i deformacije određeni korelacijom digitalne slike pri sili od 6 kN: a) polje pomaka na površini uzorka OF2, b) raspodjela deformacija na površini uzorka OF2	94
Slika 86.	Pomaci i deformacije određeni metodom konačnih elemenata pri sili od 6 kN: a) polje pomaka na modelu OF2, b) raspodjela deformacija na modelu OF2.....	95
Slika 87.	Presjek na modelu OF2	95
Slika 88.	Pomaci duž presjeka na ispitnom uzorku OF2 pri sili od 3 kN	96
Slika 89.	Deformacije duž presjeka na ispitnom uzorku OF2 pri sili od 3 kN	96
Slika 90.	Pomaci duž presjeka na ispitnom uzorku OF2 pri sili od 6 kN	97
Slika 91.	Deformacije duž presjeka na ispitnom uzorku OF2 pri sili od 6 kN	97
Slika 92.	Maksimalne deformacije po presjeku ovčjih femura pri sili od 3 kN.....	98
Slika 93.	Maksimalni pomaci po presjeku ovčjih femura pri sili od 3 kN.....	98

Slika 94.	Maksimalne deformacije po presjeku ovčjih femura pri sili od 6 kN.....	99
Slika 95.	Maksimalni pomaci po presjeku ovčjih femura pri sili od 6 kN.....	99
Slika 96.	Prosječna relativna pogreška maksimalnih deformacija svih pet uzoraka ovčjih femura pri sili od 3 kN i 6 kN	100
Slika 97.	Pomaci i deformacije određeni korelacijom digitalne slike pri sili od 6 kN: a) polje pomaka na površini uzorka KF2, b) raspodjela deformacija na površini uzorka KF2	101
Slika 98.	Pomaci i deformacije određeni metodom konačnih elemenata pri sili od 6 kN: a) polje pomaka na modelu KF2, b) raspodjela deformacija na modelu KF2.....	102
Slika 99.	Presjek na KF2 modelu	102
Slika 100.	Pomaci duž presjeka na ispitnom uzorku KF2 pri sili od 6 kN	103
Slika 101.	Deformacije duž presjeka na ispitnom uzorku KF2 pri sili od 6 kN	103
Slika 102.	Maksimalne deformacije po presjeku kadaveričnih femura pri sili od 3 kN.....	104
Slika 103.	Maksimalni pomaci po presjeku kadaveričnih femura pri sili od 3 kN.....	105
Slika 104.	Maksimalne deformacije po presjeku kadaveričnih femura pri sili od 6 kN.....	105
Slika 105.	Maksimalni pomaci po presjeku kadaveričnih femura pri sili od 6 Kn.....	106
Slika 106.	Srednja vrijednost relativne pogreške maksimalnih deformacija uzoraka KF1, KF2 i KF3 pri sili od 3 kN i 6 kN	106

Popis tablica

Tablica 1. Broj ispitanih uzoraka svinjskih femura.....	41
Tablica 2. Uobičajene vrijednosti Hounsfieldova broja.....	53
Tablica 3. Parametri korišteni tijekom CT-skeniranja	61
Tablica 4. Približan broj CT-slojeva generiran za pojedinu grupu kosti	61
Tablica 5. Rasponi Hounsfieldova broja korišteni pri definiranju maske.....	63
Tablica 6. Ispitivanje konvergencije modela svinjske kosti.....	65
Tablica 7. Izmjerene vrijednosti za HU i podaci o gustoći kalibracijskog fantoma	69
Tablica 8. $\rho_{QCT} \rightarrow HU$ relacija za svinjske, ovčje i kadaverične kosti	71
Tablica 9. Tablični prikaz relacija gustoća – modul elastičnosti kosti	75
Tablica 10. Iznosi opterećenja za pojedine grupe kostiju	81
Tablica 11. Maksimalna postignuta sila i srednja debljina kortikalisa svježih svinjskih femura	83
Tablica 12. Maksimalna postignuta sila i srednja debljina kortikalisa odmrznutih svinjskih femura.....	84
Tablica 13. Sile loma i prosječne vrijednosti gustoće svinjskih femura	94
Tablica 14. Sile loma i prosječne vrijednosti gustoće ovčjih femura.....	101
Tablica 15. Sile loma i srednje vrijednosti gustoće kadaveričnih femura.....	107

Popis važnijih oznaka

<u>Oznaka</u>	<u>Opis</u>
a	bezdimenzijski parametar
b	bezdimenzijski parametar
C	korelacijski koeficijent
E	modul elastičnosti
f	funkcija raspodjele intenziteta sive boje u referentnoj konfiguraciji
\mathbf{F}	matrica intenziteta nijansi sive boje u referentnoj konfiguraciji
g	funkcija raspodjele intenziteta sive boje u deformiranoj konfiguraciji
\mathbf{G}	matrica intenziteta nijansi sive boje u deformiranoj konfiguraciji
h	vertikalna udaljenost od vrha femoralne glave do gornjeg ruba cijevi
HU	Hounsfieldov broj
m	broj piksela u vertikalnom smjeru
n	broj piksela u horizontalnom smjeru
R^2	koeficijent determinacije
s	globalni stupanj gustoće mreže konačnih elemenata
u	pomak
x, y	koordinate točke u referentnoj konfiguraciji
x^*, y^*	koordinate točke u deformiranoj konfiguraciji
Z	funkcija preslikavanja iz referentne u deformiranu konfiguraciju
μ	linearni koeficijent atenuacije
ν	Poissonov faktor
ρ	gustoća
ρ_{QCT}	radiološka gustoća kosti
ρ_{ash}	gustoća koštanog pepela
ρ_{app}	prividna gustoća kosti

1. UVOD

1.1. Motivacija

Danas većina biomehaničkih istraživanja zahtijeva povezivanje više različitih disciplina. Razvoj eksperimentalnih i numeričkih metoda u strojarstvu potaknuo je njihovu sve češću primjenu u medicini. Primjerice, u istraživanjima koja se bave mehaničkim ponašanjem kostiju, prijelomima i analizom stabilnosti implantata, medicina i strojarstvo sve se više dopunjuju. U vezi s tim Laboratorij za eksperimentalnu mehaniku Fakulteta strojarstva i brodogradnje Sveučilišta u Zagrebu učinio je velik iskorak tako što je, u suradnji s traumatolozima i ortopedima, proveo suvremene biomehaničke studije o liječenju prijeloma proksimalnoga i distalnog humerusa pločicama na zaključavanje [1]. Spomenute biomehaničke studije obuhvaćale su eksperimentalno ispitivanje i numeričko modeliranje samih implantata te sustava kost – implantat. Eksperimentalna ispitivanja provedena su na umjetnim kostima, a tijekom numeričkog modeliranja metodom konačnih elemenata kosti su modelirane kao homogeni materijal s izotropnim svojstvima. Tijekom eksperimentalnog ispitivanja polje pomaka koštanih fragmenata mjereno je suvremenom optičkom metodom koja se naziva *korelacija digitalne slike*. Ova istraživanja poslužila su kao motivacija za primjenu spomenute metode za mjerenje pomaka i deformacija na svježim životinjskim i kadaveričnim kostima u sklopu ovoga doktorskog rada. Kako je danas cilj što bolje razviti numeričke modele kako bi računalne simulacije mogle zamijeniti skupi eksperiment, potrebni su što točniji parametri materijala. Važno je napomenuti da računalne simulacije koje se temelje na numeričkim metodama ne mogu potpuno zamijeniti eksperiment jer daju približne vrijednosti. Stoga se rezultati numeričkih simulacija moraju validirati eksperimentalnim ispitivanjem. To posebice dolazi do izražaja kod heterogenih materijala kao što je kost. Kako bi se kost što točnije numerički modelirala kao nehomogen materijal, za dobivanje geometrije i materijalnih svojstava koristi se metoda koja će dati podatke o svojstvima ne samo na površini nego i po debljini kosti. Jedna od metoda koja to omogućuje jest računalna tomografija na kojoj se temelje numerički modeli kosti korišteni u sklopu ovoga doktorskog rada. Mehanička *in vitro* ispitivanja u sklopu ovog istraživanja obavljena su na svježim bedrenim kostima svinje, ovce i kadavera da bi se validirali numerički modeli mehaničkog ponašanja kostiju.

1.2. Pregled dosadašnjih istraživanja

Kako je kost, odnosno koštano tkivo heterogen materijal, eksperimentalno ispitivanje je od posebno velikog značenja. Stoga su u prvom dijelu pregleda literature prikazana istraživanja vezana za eksperimentalno ispitivanje kosti. Navedene su publikacije koje obuhvaćaju usporedbu životinjskih i ljudskih kostiju kad je riječ o gustoći i građi te postupku pripreme koštanoga tkiva za mehaničko ispitivanje. U drugom dijelu navedena je literatura koja opisuje mehanička svojstva kosti dobivena eksperimentalnim ispitivanjem. Zatim slijede istraživanja koja se bave primjenom metode korelacije digitalne slike za mjerenje cijelog polja pomaka. Treći dio vezan je za numeričko modeliranje kosti metodom konačnih elemenata. Spomenuta istraživanja u kojima autori ispituju numeričke modele bazira se na računalnoj tomografiji.

Eksperimentalno ispitivanje kosti zahtijeva pravilnu pripremu i adekvatno skladištenje kosti. Autoliza počinje samo nekoliko sati nakon odvajanja kosti od tijela i to negativno utječe na mehanička svojstva, što su u svojim istraživanjima pokazali Sedlin [2] i Burstein [3]. Stoga treba imati na umu da su podaci dobiveni mehaničkim ispitivanjima kostiju više relativni nego apsolutni, osim u slučaju kada je kost ispitana neposredno nakon eksplantacije. Jedan od problema koji se mogu pojaviti ako je kost predugo na sobnoj temperaturi jest sušenje, tj. gubitak vlažnosti, što ima velik utjecaj na modul elastičnosti same kosti [4]. Još davno su Evans [5] i Dempster [6] pokazali da se isušivanjem kosti povećava Youngov modul elastičnosti, a žilavost se smanjuje. U svojem istraživanju [7] Evans i Lebow ističu da nakon sušenja cijeloga ljudskog femura modul elastičnosti raste za 17 %, vlačna čvrstoća za 31 %, a žilavost opada za 55 %. Sušenje kosti također znatno utječe na viskoelastična svojstva jer, ako izgubi vlažnost, kost se počinje ponašati kao idealna opruga [4]. Stoga je većina eksperimentalnih ispitivanja u literaturi obavljena na svježim kostima koje su vlažne zamrznute na -20 °C ili -70 °C radi zadržavanja mehaničkih svojstava i vlažnosti, a odmrznute su neposredno prije ispitivanja. Pelker [8] je dokazao da nema bitnih razlika ako su kosti prije ispitivanja zamrznute na -20 °C ili -70 °C. U Ashmanovu istraživanju [9] pokazano je da čuvanje zamrznute kosti 30 dana na temperaturi od -20 °C uzrokuje pad modula elastičnosti za manje od 2 %. Van Haaren je u svojem istraživanju istaknuo da čuvanje zamrznute kozje kosti godinu dana nije znatnije utjecalo na mehanička svojstva koštanog materijala [10]. Temperatura na kojoj se provode mehanička ispitivanja također utječe na konačne rezultate, posebice ako se radi o ispitivanju kosti na zamor, što su analizirali Carter i Hayes [11]. U spomenutom istraživanju kost ispitivana na sobnoj temperaturi izdržala je

dvostruko više ciklusa u usporedbi s kosti ispitivanoj pri temperaturi od 37°C. Pri statičkom ispitivanju modul elastičnosti veći je samo 2 do 4 % pri ispitivanju na sobnoj temperaturi [4]. Zbog nedostupnosti kostiju kadavera eksperimentalna *in vitro* ispitivanja često se obavljaju na životinjskim kostima [12]. Zbog lakše dobavljalivosti u usporedbi s kadaveričnom kosti, životinjske kosti korištene su za mnoga istraživanja vezana za razvoj i unaprjeđenje operacijskih zahvata, testiranje i razvoj novih medicinskih implantata pa sve do analize koštanih stanica [13, 14]. S obzirom na anatomsku građu, geometriju, cijeljenje i koštanu pregradnju, svinjske i ovčje kosti dobra su alternativa kadaveričnima [12]. Postoje životinjske vrste čije su kosti još sličnije ljudskima, no takve su vrste najčešće ugrožene ili zaštićene te je slično kao i kod kadaveričnih kostiju problematična njihva dobava [15, 16]. Svinjske kosti uglavnom su zastupljene u istraživanjima koja se bave prijelomima kostiju i hrskavice, cijeljenjem kostiju te mehaničkim ispitivanjem implantata [17, 18]. Iako te kosti dimenzijama odstupaju od ljudskih, gustoća kortikalnoga i trabekularnog dijela približno je jednaka kao i kod ljudi [19]. Sličnosti su uočene i u promjeru poprečnog presjeka femuralne glave [17]. Kad je riječ o koštanoj pregradnji, postoji sličnost s ljudskim kostima i kod trabekularne i kod kortikalne kosti [20]. U ortopedskim istraživanjima zastupljene su i ovčje kosti jer su po obliku i dimenzijama prikladne za testiranje medicinskih implantata i proteza namijenjenih ljudima. Makroskopski, ovčje su kosti dosta slične ljudskima, no histološki postoje razlike u strukturi. Razlika je i u gustoći, posebice kod trabekularnog dijela koji kod ovce može imati 1,5 do 2 puta veću gustoću od ljudske [21]. U vezi s cijeljenjem i koštanom pregradnjom nekoliko autora istaknulo je sličnosti između ljudskih i ovčjih kostiju [23, 24]. Tako Willie u svojem istraživanju [24] analizira uraštanje kosti u porozni implantat umetnut u ljudski i ovčji distalni femur. Turner [25] na osnovi svojih istraživanja zaključuje da ovčje kosti mogu biti model ljudske osteopenične i osteoporotične kosti. Pasje su kosti mikroskopski vrlo slične ljudskima, no makroskopski su znatno različite pa su pogodne samo za ispitivanje malih uzoraka kostiju [26]. Kuhn [27] u svojem istraživanju ističe da postoji velika sličnost u mehaničkim svojstvima i masi trabekularnog dijela distalnog femura kod ljudi i pasa. Također navodi da pasja trabekularna kost može podnijeti veće tlačno opterećenje [17]. Nekoliko autora pokazalo je da, unutar pasa kao životinjske vrste, postoje velike razlike u brzini koštane pregradnje između pojedinih pasmina i zato se njihove kosti nisu i ne mogu uspoređivati s ljudskim [28]. Mnogi autori fokusiraju se na mikrorazinu, odnosno na numeričko modeliranje i mehaničko ispitivanje vrlo malih uzoraka kako bi se minimizirala razlika u morfologiji i da bi utjecaj nehomogenosti kostiju bio što manji [29]. Danas se dosta istraživanja obavlja na modelima umjetnih kostiju napravljenih najčešće od kompozitnog

materijala [30]. Kad je riječ o oblicima i dimenzijama, oni mogu biti dobra alternativa kadaveričnim kostima, no ima odstupanja u mehaničkim svojstvima zbog velikih razlika na mikrorazini [31]. Neki autori dokazali su razlike u mehaničkom ponašanju između kadaveričnih i umjetnih kostiju i zaključili da umjetne kosti ne mogu obuhvatiti neke lokalne promjene koje se pojavljuju na svježim kostima [30, 31]. Te razlike proizlaze iz kompleksnosti mikrostrukture svježih kostiju koju umjetne kosti nemaju. Umjetne kosti mogu biti jako dobra alternativa ako se eksperimentalno ispituje sustav kost – implantat zbog usporedbe mehaničkih svojstava implantata [1].

Eksperimentalno ispitivanje kostiju može se podijeliti na dva dijela – na ispitivanje malih uzoraka koštanog tkiva i na ispitivanje cijelih segmenata kostiju (npr. cijeli proksimalni dio kosti, distalni dio, cijela kost, itd.). Ispitivanjem malih uzoraka dobivaju se parametri materijala i definiraju konstitutivni zakoni, a ispitivanje cijelih kostiju obavlja se zbog validacije numeričkih modela. Elastična svojstva koštanog tkiva na makrorazini određuju se klasičnim tlačnim, vlačnim i savojnim ispitivanjima malih uzoraka kojima su se bavili Reilly [32] i Currey [33]. Modul elastičnosti kortikalnog koštanog tkiva približno je isti za vlačno i tlačno opterećenje [34]. Torzijsko ispitivanje i oštećenje ljudskoga kortikalnog tkiva analizirao je Jepsen [35], a Lakes je sa suradnicima, tijekom biaksijalnih ispitivanja, odredio viskoelastična svojstva [36]. Neki se autori u svojim istraživanjima koriste ultrazvučnom tehnikom za određivanje elastičnih svojstava ljudskih i životinjskih kostiju [37, 38, 39]. Rho [40] i Hoffler [41] u svojim publikacijama ističu da su se koristili tehnikom nanoutiskivanja kojom se mogu odrediti anizotropna elastična svojstva. Pokazano je također da mehanička svojstva ovise o vrsti kosti i da postoje određene varijacije u svojstvima unutar različitog područja iste kosti [42]. Razlike u mehaničkim svojstvima između kortikalnoga i trabekularnog koštanog tkiva analizirane su u publikacijama [43] i [44]. U dosta radova opisane su ovisnosti mehaničkih svojstava o gustoći i mineralnom sastavu kosti [45]. Helgason u svojem preglednom radu ističe ovisnost mehaničkih svojstava o gustoći kosti [46]. Neki istraživači bave se mehaničkim ispitivanjem koštanoga tkiva na mikrorazini [40] te opisuju mehaničko ponašanje osteona pri vlačnom, savojnom i torzijskom opterećenju [45]. Zbog validacije nekih konstitutivnih zakona mnogi istraživači provode mehanička ispitivanja na velikim uzorcima, odnosno na cijelim kostima [47, 48, 49, 50]. U spomenutim istraživanjima provedeno je tlačno kvazistatičko ispitivanje kadaveričnoga proksimalnog femura te su dobiveni rezultati poslužili za validaciju numeričkih modela i za predikciju mjesta i granične sile loma kosti.

Pri ispitivanju malih uzoraka, najčešće malih valjčića ili kockica izrezanih iz nekog dijela kosti, pomaci i deformacije mjere se mehaničkim i laserskim ekstenzometrima ili se podatak o pomaku uzima direktno s uređaja za opterećivanje. Ako se ispituje veći segment kosti ili cijela kost, većina autora za mjerenje deformacija koristi se elektrootpornim mjernim trakama (tenzometrima) [49, 50]. Prednost tenzometara je visoka točnost mjerenja deformacija, a nedostatak je što mjere lokalno na vrlo malom segmentu, gotovo u točki [50]. Suvremena optička metoda koja kao rezultat daje cijelo polje pomaka, metoda je korelacije digitalne slike (DIC). Spomenuta metoda prvi je put primijenjena početkom 80-ih godina 20. stoljeća [51]. Jedna je od uobičajenih metoda koje se koriste za dobivanje mehaničkih svojstava inženjerskih materijala. Područje u kojem se ova metoda sve češće upotrebljava jest biomehanika, odnosno biološka tkiva [52]. U svojem istraživanju Luyckx [53] primjenjuje tu metodu za mjerenje polja pomaka i deformacija u tri dimenzije na površini Ahilove tetive koju je vlačno ispitivao *in vitro*. Zaključio je da je metoda vrlo precizna i primjenjiva na biološka tkiva. Moerman [54] je pokazao kako metoda korelacije digitalne slike, u kombinaciji s metodom konačnih elemenata, može biti moćan alat za određivanje parametara Neo-Hookova konstitutivnog zakona za hiperelastične materijale. Zhang [55, 56] se koristio DIC-om za mjerenje velikih deformacija na površini uzoraka izrezanih iz aorte goveda. Uzorci su podvrgnuti uniaksijalnom vlačnom ispitivanju i izmjerene su deformacije i do 40 %. Arterijsko tkivo kompozitni je materijal koji se sastoji od elastina i kolagena i pokazuje izrazito nelinearan odziv u slučaju velikih deformacija [56]. Isti autor u istraživanju [57] o mjerenju spomenutom metodom, određuje Poissonov faktor. Metoda korelacije digitalne slike nekoliko je puta korištena i validirana na primjeru umjetnih kostiju [58]. Tako Grassi u svojem istraživanju [59] eksperimentalno ispituje umjetni proksimalni femur četvrte generacije i za validaciju numeričkog modela koristi se deformacijama izmjerenima s pomoću korelacije digitalne slike. Tlačno aksijalno opterećenje, narinuto je na femoralnu glavu, a distalni dio drži se fiksno. U samo nekoliko istraživanja metoda DIC korištena je za provedbu *in vitro* eksperimenta na svježim životinjskim ili ljudskim kostima [60, 61, 62]. Yavari je u svojem istraživanju [60] pokazao da se na osnovi ekvivalentnih deformacija izmjerenih na svježim kostima štakora uz pomoć DIC-a mogu postaviti i međusobno usporediti određeni kriteriji loma. Na jednoj strani kosti narinuto je tlačno aksijalno opterećenje, a druga strana kosti držana je fiksno. Kosti su opterećivane do loma koji se pojavljuje u području najvećih vlačnih deformacija, iako se lokalno na nekim mjestima pojavljuju tlačne deformacije koje su po apsolutnoj vrijednosti veće od vlačnih [14]. Primjenom DIC-a Sztefek u svojem istraživanju pokazuje kako adaptiranje kosti na određeno

mehaničko opterećenje utječe na raspodjelu deformacija na njezinoj površini [62]. Zaključuje da su vršne vrijednosti deformacija manje na adaptiranoj kosti te da je raspodjela deformacija kontinuiranija.

U većini biomehaničkih studija kojima su tema kosti, sve se češće provodi i numeričko modeliranje metodom konačnih elementa. Metoda konačnih elemenata omogućila je da se rezultati mjerenja na malim segmentima kosti (mikrorazina) ekstrapoliraju na makrorazinu te da se na taj način analizira mehaničko ponašanje cijele kosti [63]. Mehanička svojstva u tom se slučaju najčešće temelje na gustoći kosti [64, 65, 66, 67]. Naravno, ovaj pristup zahtijeva mnogo mehaničkih i kliničkih ispitivanja. Tako se može promatrati odziv kosti na mehaničko opterećenje i procijeniti rizik od loma, a može se obaviti i predoperacijsko planiranje [68]. Pri analizi cijelih kostiju većina autora modelira kost upravo kao linearno-elastičan nehomogeni materijal s izotropnim svojstvima [69, 70, 71, 73, 74, 75]. U literaturi se često navodi da je koštano tkivo ortotropni materijal [76, 77]. Jedan od krucijalnih problema jest definiranje glavnih osi ortotropije, posebice u slučaju spongiozne kosti kod koje raspored i položaj koštanih gredica jako varira unutar kosti [76]. Peng [76], Baca [77] i Wirtz [78] u svojim istraživanjima ističu da modeliranje kosti kao ortotropni materijal daje realnije rezultate u usporedbi s izotropnim modelom isključivo kada se radi o iznimno malim uzorcima. Na osnovi svojih istraživanja zaključuju da je na većim uzorcima i cijelim kostima razlika u rezultatima zanemariva, ako se koristi nehomogeni numerički model [76, 77, 78]. Kost se također u nekim istraživanjima modelira kao izotropno-homogeni materijal, najčešće ako je riječ o analizi sustava kost – implantat, s obzirom na to da je većini takvih analiza krajnji cilj međusobna usporedba nekoliko različitih implantata ili načina fiksacije implantata na kost [1]. Numerički modeli kosti temeljeni na metodi konačnih elemenata danas se sve češće temelje na računalnoj tomografiji, što se vidi u mnogobrojnim istraživanjima [69, 70, 71, 73]. U tim istraživanjima računalna tomografija koristi se za rekonstrukciju geometrije i za generiranje nehomogenih materijalnih svojstava koja proizlaze iz gustoće kosti, odnosno Hounsfieldova broja. Većina autora pokazala je da je veza između faktora atenuacije, odnosno Hounsfieldova broja i mineralne gustoće kosti (engl. *BMD – Bone Mineral Density*) linearna [48, 49, 50, 69, 71]. Ta veza individualna je za svaki CT uređaj, a određuje se s pomoću posebnoga kalibracijskog fantoma za mjerenje gustoće kosti. Gustoća kosti (*apparent density*) povezana je s mineralnom gustoćom kosti [68, 73]. S obzirom na to da se model diskretizira mrežom konačnih elemenata, potrebno je svojstva koja su dodijeljena na razini vokselâ preslikati na mrežu konačnih elemenata kako bi se svakom elementu dodijelio individualni modul elastičnosti. Za to postoji nekoliko pristupa. Prvi pristup temelji se na izračunu modula

elastičnosti svakog vokselu na temelju gustoće koja proizlazi iz CT-broja (Hounsfieldova broja). Svakom konačnom elementu dodjeljuje se srednja vrijednost modula elastičnosti svih vokselu koji se nalaze unutar toga elementa [71, 74]. Drugim pristupom najprije se određuje srednja vrijednost CT-broja svih vokselu koji se nalaze unutar jednog konačnog elementa i naknadno se računaju gustoća i modul elastičnosti u svakom konačnom elementu [69]. Chen u svojem istraživanju [75] uvodi pristup koji se temelji na dodjeljivanju parametara materijala direktno u točke integracije konačnog elementa. Temelji se na traženju okolnih vokselu za svaku točku integracije i izračunu srednje vrijednosti Hounsfieldova broja iz kojeg onda opet slijede gustoća i modul elastičnosti [75]. Eberle [68] i Austman [71] u svojim radovima ističu da pravilan odabir relacije gustoća – modul elastičnosti znatno utječe na rezultate računalnih simulacija. U literaturi je navedeno više izraza koji povezuju te dvije veličine i najčešće su to linearne ili eksponencijalne funkcije i definirane su za ljudski femur [48, 64, 65, 66, 67]. Pokazano je da su neki od tih izraza mogu primijeniti za cijelo područje gustoće kosti, a neki su ograničeni na područje povišene ili smanjene gustoće, tj. na kompaktnu ili spongioznu kost. Neke od tih relacija korištene su i za numeričko modeliranje ljudske tibije i radijusa [70]. U svakom od tih istraživanja rezultati računalnih simulacija uspoređeni su s rezultatima dobivenima eksperimentalnim ispitivanjem, pri čemu su deformacije mjerene tenzometrima.

1.3. Ciljevi i hipoteze istraživanja

Na osnovi pregleda dosadašnjih istraživanja jasno je da postoje otvorena pitanja u izboru odgovarajuće relacije gustoća – modul elastičnosti kojima se koristimo za numeričko modeliranje kosti metodom konačnih elemenata. Nedostatak validacije numeričkih modela mehaničkog ponašanja kosti uočen je kod životinjskih kostiju koje se često koriste za pretklinička ispitivanja medicinskih implantata i novih kirurških tehnika. Također, u vrlo malo istraživanja za mjerenje cijelog polja pomaka i deformacija primijenjena je metoda DIC koja bi mogla dati bolji uvid u mehaničko ponašanje kostiju. U tom smislu postavljeni su ciljevi i hipoteze ovog doktorskog rada.

Cilj predloženog istraživanja jest primjena metode korelacije digitalne slike (DIC) za mjerenje cijelog polja pomaka na površini svježih životinjskih i kadaveričnih kostiju u *in vitro* eksperimentalnim ispitivanjima. Jedan od ciljeva jest i ispitati može li se metodologija kreiranja MKE modela kadaveričnih kostiju, temeljenog na računalnoj tomografiji, primijeniti

i na životinjske kosti. S obzirom na to da su u literaturi informacije o povezanosti gustoće i modula elastičnosti životinjskih kostiju nedostatne, cilj je odrediti koju od postojećih relacija odabrati pri numeričkom modeliranju svinjskih i ovčjih kostiju. Numerički modeli cijelih kostiju temeljeni na računalnoj tomografiji validirat će se eksperimentalnim ispitivanjem tih istih kostiju, pri čemu će se pomaci i deformacije odrediti s pomoću DIC-a.

Hipoteze:

- Metoda korelacije digitalne slike primjenjiva je za mjerenje pomaka i deformacija na površini svježih životinjskih i kadaveričnih kostiju i omogućuje pouzdaniju validaciju mehaničkog ponašanja kostiju.
- Pretpostavlja se da postoje relacije gustoća – modul elastičnosti koje se, osim za opisivanje parametara materijala kadaveričnih femura, mogu primijeniti na svinjske i ovčje femure.
- Metodologija kreiranja numeričkog modela kadaveričnih kostiju, koji se bazira na računalnoj tomografiji, može se primijeniti i na životinjske kosti.

1.4. Očekivani znanstveni doprinos

Primjena metode korelacije digitalne slike tijekom eksperimentalnog ispitivanja svježih životinjskih i kadaveričnih kostiju omogućit će dobivanje cijelog polja pomaka i deformacija na površini kosti čime će se pridonijeti boljem razumijevanju mehaničkog ponašanja kosti i njezina odziva na narinuto opterećenje. Pravilan odabir relacije gustoća – modul elastičnosti za numeričke modele životinjskih kostiju koji se bazira na računalnoj tomografiji znatno će pridonijeti točnosti računalnih simulacija koje se sve češće primjenjuju u biomehaničkim i medicinskim istraživanjima. Numerički modeli pojednostavit će predoperacijske radnje kad je riječ o pouzdanijem određivanju vrste i veličine implantata, položaju implantata na kosti, vrsti i broju vijaka za adekvatno fiksiranje implantata i riziku od ponovnoga loma.

1.5. Struktura rada

Rad je podijeljen u osam poglavlja. Prvo poglavlje je uvodno i u njemu je iznesena motivacija i detaljan pregled literature u kojemu je prikazano trenutačno stanje područja istraživanja. Dan je i pregled eksperimentalnih *in vitro* ispitivanja koštanog materijala te su navedena

istraživanja koja se bave primjenom metode korelacije digitalne slike za mjerenje pomaka i deformacija na biološkim tkivima. Prikazane su razlike u građi i mehaničkim svojstvima između ljudskih i životinjskih kostiju koje su sve češće predmet biomehaničkih istraživanja. Također je dan pregled radova koji se bave numeričkim modeliranjem kosti na osnovi računalne tomografije. Na temelju pregleda literature navedena su otvorena pitanja na osnovi kojih su definirani ciljevi i hipoteze rada.

U drugom poglavlju dan je pregled hijerarhijske strukture koštanoga tkiva i makroskopska građa kosti koja obuhvaća njezin kortikalni i trabekularni dio kosti. Opisana je i građa bedrene kosti koja je predmet ovog istraživanja, a prikazani su i neki karakteristični prijelomi koji se operativno liječe.

U trećem poglavlju nabrojene su najčešće korištene metode mjerenja pomaka i deformacija u eksperimentalnoj mehanici. Ukratko je opisano mjerenje pomaka vertikalnim hodom kidalice, mehaničkim i laserskim ekstenzometrima te mjerenje deformacija elektrootpornim mjernim trakama. Nakon toga detaljno je opisan princip metode korelacije digitalne slike i mjerenje optičkim sustavom *Aramis* koji je korišten u sklopu ovog istraživanja.

U četvrtom poglavlju detaljno je opisano eksperimentalno ispitivanje svježih svinjskih, ovčjih i kadaveričnih femura. Svježe svinjske kosti dobivene su iz klaonice unutar 24 sata od usmrćivanja, a svježe ovčje kosti pribavljene su u suradnji s Veterinarskim fakultetom Sveučilišta u Zagrebu unutar tri sata od eutanazije. Kost kadavera osigurao je Zavod za anatomiju Medicinskog fakulteta Sveučilišta u Rijeci. Sva eksperimentalna ispitivanja provedena su u Laboratoriju za eksperimentalnu mehaniku Fakulteta strojarstva i brodogradnje Sveučilišta u Zagrebu. Svinjske kosti najprije su podvrgnute savijanju u tri točke. Dio kosti čuvan je zamrznut 30 dana i nakon toga je ispitan, a dio je ispitan odmah nakon zaprimanja. Nakon toga prikazan je postupak tlačnog opterećivanja svinjskih, ovčjih i kadaveričnih femura, pri čemu su pomaci i deformacije određeni DIC-om, što je poslužilo za validaciju numeričkih modela kosti.

U petom poglavlju detaljno je opisan princip računalne tomografije na osnovi koje je generiran numerički model kosti. Ukratko je objašnjen način rada CT-uređaja i artefakti koji se pojavljuju tijekom snimanja. Prikazano je kako se na osnovi računalne tomografije

određuje gustoća kosti, što je važno za definiranje nehomogenih materijalnih svojstava na numeričkom modelu kosti.

U šestom poglavlju detaljno je objašnjeno kreiranje numeričkog modela kosti na osnovi računalne tomografije. Sve kosti spomenute u četvrtom poglavlju koje su bile tlačno opterećene prethodno su podvrgnute CT-u. CT-snimanja kostiju obavljena su u Kliničkom zavodu za dijagnostičku i intervencijsku radiologiju KB-a Merkur. Na osnovi CT-snimaka rekonstruirana je geometrija kosti. U nastavku šestog poglavlja detaljno je objašnjen nehomogeni numerički model koji se temelji na izračunu gustoće kosti i modula elastičnosti na osnovi polja Hounsfieldova broja dobivenog CT-om. Prikazane su relacije gustoća – modul elastičnosti, koje će poslužiti za definiranje materijalnog modela. Definirana je mreža konačnih elemenata te rubni uvjeti i opterećenje koji simuliraju eksperimentalno ispitivanje u četvrtom poglavlju.

U sedmom poglavlju dani su rezultati eksperimentalnog ispitivanja i numeričkog modeliranja. Tu su i rezultati za pomake i deformacije po presjeku definiranom po duljini kosti, kako bi se dobio odziv cijeloga ispitnog uzorka na narinuto opterećenje i da bi se odredile lokalne promjene deformacija u blizini vrata femura. Dijagramski je dana usporedba rezultata računalnih simulacija i rezultata eksperimenata dobivenih korelacijom digitalne slike.


U osmom poglavlju su zaključci istraživanja te su definirane smjernice za buduća istraživanja.

2. KOST I KOŠTANO TKIVO

Kosti su organi koji čine koštani sustav, a živo su tkivo koje podupire tjelesnu strukturu. U literaturi se kost često navodi kao čvrsto tkivo (engl. *Hard tissue*), a katkad se naziva i mineraliziranim tkivom. Razlog je što su krutost i tvrdoća koštanog materijala mnogo veći u usporedbi s ostalim živim, tj. mekim tkivom (engl. *Soft tissue*). Kosti služe kao hvatišta mišićima, omogućuju kretanje i imaju svojstvo prilagođivanja i pregradnje, ovisno o opterećenju. Osim toga imaju i zaštitnu ulogu – štite vitalne organe kao što su mozak, leđna moždina, srce i pluća. Prema obliku kosti se dijele na duge (kosti udova), kratke (stopalo, kralješci, šaka) i plosnate (lubanja, zdjelica, lopatica).

2.1. Građa kosti

Kost je građena od 70 % anorganske tvari (najvećim dijelom kalcija i fosfora), 22 % organske (kolagena) i 8 % vode. Dakle, s obzirom na građu, kost se može smatrati kompozitom koji je čvrst zahvaljujući kalciju, istodobno je i elastičan jer sadržava organski matriks te viskoelastičan zahvaljujući vodi. Koštano tkivo sastoji se od nekoliko sastavnih strukturnih faza koje se nalaze na slici 1.




Slika 1. Hijerarhijska struktura koštanog tkiva na primjeru ljudske bedrene kosti [79]

Organski dio kosti čine koštane stanice – osteociti, osteoklasti i osteoblasti te međustanična tvar u kojoj dominiraju kolagena vlakna. Makroskopski gledano, kost izgrađuje kortikalno i trabekularno koštano tkivo. Trabekularna kost još se naziva spongioznom ili spužvastom kosti. Histološki, koštano tkivo ima lamelarnu strukturu i osnovna jedinica je osteon. U sredini osteona je Haversov kanal (od 10 do 500 μm). Kružne lamele koje ga okružuju mogu biti veličine 3 do 7 μm . Ako se promatra još sitnija struktura kosti (do 1 μm), tada se govori o nanostrukтури, što podrazumijeva kolagena vlakna i mineralne kristale. Kristali hidroksiapatita vezani su za kolagena vlakna i tako se organski matriks mineralizira. Težište ovoga doktorskog rada je na analizi mehaničkog ponašanja kosti na makroskopskoj razini.

2.1.1. Kortikalna kost

Kortikalna kost gusta je i kompaktna koštana tvar. Izgrađuje površni sloj kostiju i u cijelosti trup dugih kostiju. Kortikalna kost, ovisno o njezinoj debljini, ima izraženu lamelarnu strukturu brojnih osteona. Haversovi kanali pružaju se paralelno s površinom kosti, a Volkmannovi kanali spuštaju se od površine kosti u dubinu okomito na Haversove kanale i tako omogućuju ulazak krvnih žila u kortikalnu kost. Na slici 2 prikazana je mikrostruktura kortikalnoga koštanog tkiva.




Slika 2. Mikrostruktura kortikalnog koštanog tkiva: a) skica kortikalne kosti, b) presjek kroz Haversov sustav, c) fotomikrografski prikaz Haversova sustava [81]

Budući da je gusta i homogena tvar, kortikalna kost sadržava najveći dio mineralnog sadržaja. U kortikalnoj kosti nalazi se 80 do 90 % kalcija, a ostatak od 15 do 25 % je u trabekularnoj kosti [80]. Kortikalno koštano tkivo karakterizira povišena gustoća u usporedbi s trabekularnim tkivom, a sastoji se od koštanih lamela koncentrično postavljenih oko kanala kroz koje prolaze krvne žile i živci, kao što se vidi na slici 2. Vanjska površina kosti, gdje je kost u doticaju s mekim tkivom, prekrivena je periostom te se naziva periostalna površina. Trup duge kosti, zato što se u njemu nalazi medularna šupljina, ima i unutarnju površinu koju prekriva endost te se naziva endostalna površina. Ta površina je u doticaju s koštanom srži koja ispunjava medularnu šupljinu (slika 1.). Periost je dobro prokrvljen i sadržava osjetna živčana vlakna. Koštana srž proizvodi većinu krvnih stanica.

2.1.2. Trabekularna kost

Kortikalna i trabekularna kost naizgled su dosta različite, no histološka im je građa jednaka. Trabekularno koštano tkivo je u obliku koštanih gredica koje formiraju trodimenzionalnu mrežu. Stoga između gredica nastaju šupljini koje ispunjava koštana srž. Osim što čine mrežastu, odnosno spužvastu strukturu, koštane grede raspoređuju se u smjeru djelovanja sile težine na kost (trajektoriji). Trabekularna kost izgrađuje okrajke dugih kostiju i kratke kosti, kao što je prikazano na longitudinalnom presjeku kroz bedrenu kost na slici 3. Zbog spužvaste građe trabekularna kost ima znatno nižu gustoću od kortikalne kosti. Takva građa čini kost laganom, a s druge strane dovoljno čvrstom da se može oduprijeti opterećenju.




Slika 3. Prikaz kortikalne i trabekularne kosti

2.2. Bedrena kost

Bedrena kost ili femur natkoljениčna je kost koja se ubraja u skupinu dugih cjevastih kostiju. To je ujedno i najduža kost u ljudskom skeletu, a može narasti i do duljine od 55 cm.

Bedrenu kost može se podijeliti na tri segmenta: proksimalni dio, trup i distalni dio. Na proksimalnom dijelu spaja se sa zdjelicom u zglob kuka, te na svojem distalnom dijelu u koljenski zglob. Na slici 4. prikazana je građa ljudskog femura na primjeru umjetnog modela kosti.




Slika 4. Građa femura

Proksimalni dio bedrene kosti počinje glavom u obliku kugle. Ispod se nalazi vrat. Na proksimalnom dijelu su i veliki i mali trohanter koji služe kao hvatište tetiva mišića. Vrat je uzak u blizini femoralne glave, a dalje se prema trupu širi. Kut koji zatvaraju os vrata i os trupa femura najčešće je između 120° i 130° .

2.3. Prijelomi bedrene kosti

Kako je bedrena kost jedna od najopterećenijih u ljudskom skeletu, često je izložena prijelomima, i to najčešće u proksimalnom dijelu. Prijelomi proksimalnog dijela femura među najvećim su problemima kojima se bavi suvremena traumatologija i čine 10 % svih prijeloma donjih ekstremiteta. Prijelome proksimalnog dijela femura može se podijeliti na intertrohanterne, subtrohanterne te prijelome vrata (slika 5.).



Slika 5. Najčešći prijelomi femura: a) intertrohanterni, b) subtrohanterni, c) prijelom vrata


Lom kosti najčešće se događa pri spoticanju i padanju, a kod starijih osoba uglavnom je posljedica osteoporoze i biomehaničkog slabljenja kostiju. Osteoporoza je bolest koštanog tkiva kod koje se progresivno smanjuje gustoća kosti, odnosno pojavljuje se gubitak organskoga i mineralnog dijela, pa kosti postaju krhke i lomljive. Ubraja se u jednu od pet najčešćih kroničnih bolesti uopće, a 80 % svih oboljelih su žene. Najčešće i najopasnije komplikacije osteoporoze su prijelom kralježaka i vrata femura. Prijelomi se najčešće liječe protezama, vijcima, pločicama na zaključavanje i intramedularnim čavlima.

3. MJERENJE POMAKA I DEFORMACIJA

Pri mehaničkom ispitivanju, bilo inženjerskih bilo bioloških materijala, mogu se mjeriti dvije osnovne veličine od kojih se jedna mjeri, a druga kontrolira. Te dvije veličine najčešće su sila i pomak i iz njih se mogu dalje izračunavati naprezanja, deformacije i određeni parametri materijala. Sila se u pravilu mjeri s pomoću specijalnih mjernih doza koje se umjeravaju posebnim dinamometrima. Mnogo veći izazov je mjerenje pomaka, odnosno deformacija.

3.1. Vertikalni hod kidalice

Najjednostavniji način mjerenja pomaka jest uzimanje podataka o vertikalnom hodu uređaja za opterećivanje, kidalice. Za slučaj statičkoga vlačnog testa, ispitni uzorak (epruveta) postavlja se na uređaj za opterećivanje tako da je jedan kraj nepomičan u čeljusti koja miruje, a drugi kraj pričvršćen je u čeljusti koja se pomiče u vertikalnom smjeru (slika 6 a). U tom slučaju podatak o izmjerenom pomaku pokazuje pomak gornje čeljusti, a deformacija se određuje na osnovi početnoga i konačnog razmaka između čeljusti. I tijekom savijanja u tri točke (slika 6. b) jedan od načina mjerenja progiba jest upravo vertikalni hod.




a) b)
Slika 6. a) Primjer vlačnog testa; b) Primjer savijanja u tri točke

Jedan od nedostataka ovakvog mjerenja prikazanog na slici 6. jest to što se mjeri pomak na vrhu ispitnog uzorka, tamo gdje je učvršćen u čeljusti, a ne na mjestu gdje se očekuje eventualni lom. Naravno, što je manji ispitni uzorak, taj nedostatak manje dolazi do izražaja. Taj pomak također sadržava sve postojeće neželjene zračnosti u adapterima i čeljustima za opterećivanje, te pogreške zbog inercije pokretnih dijelova. Ako se radi o graničnim iznosima sile koju uređaj za opterećivanje može postići, tada i njegova krutost utječe na rezultirajući pomak. Zato postoje korekcijski faktori na osnovi kojih se u ovakvim slučajevima korigira dobiveni pomak.

3.2. Mehanički ekstenzometar

Ekstenzometri su uređaji koji se koriste za mjerenje relativnog pomaka dviju odabranih točaka na epruveti na osnovi kojeg se može izračunati deformacija epruvete. Više je vrsta ekstenzometara: mehanički ekstenzometar, elektrootporne mjerne trake, videoekstenzometar, laserski ekstenzometar i dr. Mehanički ekstenzometar kompaktan je i veoma precizan. Glavni nedostatak mu je ograničeno područje mjerenja te zato nije prikladan za ispitivanje materijala koji imaju veliku istezljivost. U većini slučajeva prije loma epruvete nužno je odspojiti ekstenzometar kako se uređaj ne bi trajno oštetiо. U takvim slučajevima može postojati odstupanje u izmjerenoj istezljivosti ispitnog uzorka. Primjer mjerenja mehaničkim ekstenzometrom prikazan je na slici 7.



Slika 7. Mjerenje mehaničkim ekstenzometrom

3.3. Laserski ekstenzometar

Razvojem digitalnih kamera visoke rezolucije i brzog prijenosa podataka, u kombinaciji s vrlo snažnim algoritmima za analizu digitalnih slika, nastaju novije generacije ekstenzometara, a najvažniji su videoekstenzometar i laserski ekstenzometar [82].

Pri mjerenju laserskim ekstenzometrom koherentno lasersko svjetlo obasjava površinu epruvete, pri čemu kamere snimaju refleksiju s površine (slika 8.). Zbog hrapavosti površine nastaje interferencija svjetlosnih zraka, te na slici nastaje zrnata struktura nasumično osvijetljenih piksela (engl. *laser speckle effect*). Svaka promatrana grupa piksela ima jedinstven uzorak čija je putanja po slici u korelaciji s razvlačenjem materijala [82].




Slika 8. Mjerenje laserskim ekstenzometrom

Glavna prednost laserskog ekstenzometra je što nema ograničenje veličine mjernog područja, kao što je to slučaj kod mehaničkoga ekstenzometra i ubraja se u neinvazivne i beskontaktno metode čime se izbjegava oštećenje ispitnog uzorka. Može se također koristiti za ispitivanja u širokom temperaturnom području.

3.4. Videoekstenzometar

Videoekstenzometar također se ubraja u neinvazivne beskontaktno metode mjerenja. Sastoji se od kamere, pozadinskog izvora svjetla i markera koji se ucrtavaju, lijepe ili nekako drukčije učvršćuju na ispitni uzorak. Slika 9. prikazuje mjerenje produljenja videoekstenzometrom na primjeru vlačnog ispitivanja aluminijske epruvete. Direktno mjeri

produljenje tako da konstantno mjeri udaljenost između pričvršćenih markera i na osnovi produljenja računa deformaciju ispitnog uzorka.




Slika 9. Mjerenje videoekstenzometrom

Snimke kamere digitaliziraju se i svaki piksel dobiva svoju vrijednost intenziteta sive boje (engl. *gray value*). Markeri dovode do promjene u sivoj skali (ljestvici) piksela duž linije snimanja i stvaraju se vrhovi koji služe kao točke mjerenja. Prednost videoekstenzometra je veliko vidno polje koje ovisi o fokalnoj duljini i udaljenosti kamere od objekta. Osim toga, istodobno se može mjeriti produljenje i kontrakcija ispitnog uzorka, što omogućuje određivanje Poissonova faktora te izračunavanje stvarnog naprezanja (engl. *True stress*) i stvarne deformacije (engl. *True strain*). Videoekstenzometar se, kao i laserski ekstenzometar, može koristiti za mjerenja u širokom temperaturnom području.

3.5. Elektrootporne mjerne trake

Elektrootporne mjerne trake najjednostavnija su grupa tenozmetara. To su zapravo žičani tenzometri koji se sastoje od tanke savijene žice zalijepljene na podlogu od tankoga acetatnog papira. S gornje strane je žičana rešetka zaštićena drugim slojem papira. Danas se najčešće upotrebljavaju tenzometri s mjernom rešetkom izrađenom od tanke folije (debljine 3 do 5 μm). Takav se tenzometar nalijepi na uzorak koji se ispituje i na osnovi izmjenjenog otpora vodiča može se odrediti deformacija. Na slici 10. prikazano je mjerenje deformacija elektrootpornim mjernim trakama na kadaveričnom femuru.




Slika 10. Mjerenje deformacija elektrootpornim trakama na svježoj kosti [83]

Prednost elektrootpornih traka je visoka točnost mjerenja, a nedostatak je zahtjevna priprema jer je potrebno osigurati da se trake čvrsto zalijepe za ispitni uzorak.

Nedostatak svih dosad spomenutih metoda jest što se baziraju na lokalnom mjerenju, tj. na mjerenju u jednoj točki, odnosno mjerenju razmaka između dvije točke (markera). Kako je područje ovog istraživanja mehaničko ponašanje kosti, potrebno je primijeniti metodu koja će kao rezultat mjerenja dati cijelo polje pomaka i deformacija na površini mjerenog objekta. Jedna od takvih metoda je korelacija digitalne slike.


3.6. Korelacija digitalne slike

Korelacija digitalne slike beskontaktna je optička metoda koja služi za određivanje polja pomaka i deformacija. Kao što se vidi na slici 11., za primjenu korelacije digitalne slike potrebna je kamera (ili više njih), izvor svjetla i odgovarajući algoritam koji će omogućiti korelaciju rezultirajućih digitalnih slika. Za snimanje se najčešće koriste kamere CCD (engl. *charge-coupled device*) ili CMOS (engl. *complementary metal-oxide-semiconductor*).




Slika 11. Shematski prikaz 3D mjerenja s dvije kamere primjenom korelacije digitalne slike

Metoda se temelji na praćenju promjena položaja točaka na površini ispitnog uzorka tako da se uspoređuje položaj mjernih točaka u deformiranom stanju s njihovim položajem u nedeformiranom stanju. Dakle, izlazni podaci mjerenja su digitalne slike, pri čemu je prva slika referentna i označava nedeformirano stanje uzorka. Digitalne slike diskretiziraju se manjim poljima piksela koja se nazivaju podskupovi (engl. *subsets*) ili fasete (engl. *facets*), što se vidi na slici 12. U središtu svake fasete nalazi se središnja točka koja je mjerna točka (engl. *measuring point*). Fasete su obično pravokutnog ili kvadratičnog oblika i svaka ima jedinstvenu raspodjelu intenziteta sive boje koja ih čini međusobno različitima. Zato je poželjno da materijal koji se ispituje ima raznoliku teksturu kad je riječ o intenzitetu nijansi sive boje. No, obično to nije slučaj te je nužna dodatna priprema ispitnog uzorka – nanošenje stohastičkog uzorka (rastera) na površinu.



Slika 12. Primjer stohastičkog rastera i crveno označena pravokutna faseta u referentnoj konfiguraciji a) i deformiranoj konfiguraciji b)

Položaj faseta u referentnoj i deformiranoj konfiguraciji, što je prikazano na slici 13., uspoređuje se s pomoću jednažbi za korelaciju digitalne slike primjenom određenih korelacijskih faktora i matematičkih kriterija usporedbe.



Slika 13. Referentna i deformirana konfiguracija

Općenito, ako se $s f(x, y)$ označi raspodjela intenziteta sive boje na referentnoj slici, a s $g(x^*, y^*)$ raspodjela intenziteta sive boje na slici deformiranoga ispitnog uzorka, tada se princip korelacije može definirati kao preslikavanje Z iz referentne u deformiranu konfiguraciju

$$g(x^*, y^*) = Z[f(x, y)], \quad (1)$$

odnosno

$$\begin{aligned} x^* &= x + u_x(x, y), \\ y^* &= y + u_y(x, y). \end{aligned} \quad (2)$$

Koordinate točke $B^*(x^*, y^*)$ u deformiranoj konfiguraciji mogu se izraziti preko koordinata u referentnoj konfiguraciji, uz pretpostavku da su gradijenti pomaka konstantni u cijeloj faseti. Tada se koordinate (x^*, y^*) mogu zapisati kao

$$\begin{aligned} x^* &= x_A + u_{x,A} + \frac{\partial u_{x,A}}{\partial x} \Delta x + \frac{\partial u_{x,A}}{\partial y} \Delta y, \\ y^* &= y_A + u_{y,A} + \frac{\partial u_{y,A}}{\partial x} \Delta x + \frac{\partial u_{y,A}}{\partial y} \Delta y. \end{aligned} \quad (3)$$

Kao što se vidi na slici 13., za Δx i Δy vrijedi

$$\begin{aligned} \Delta x &= x - x_A, \\ \Delta y &= y - y_A. \end{aligned} \quad (4)$$

Točke A i B u referentnoj konfiguraciji preslikavaju se u točke A* i B* u deformiranoj konfiguraciji, pri čemu se promjena položaja točke A u A* interpretira kao pomak, a koordinate točke B* dane su izrazima (3). Koeficijent koji je kriterij podudarnosti dviju raspodjela intenziteta sive boje između dvije fasete, naziva se korelacijski koeficijent C. Ovaj koeficijent je za slučaj dvodimenzijanskog mjerenja funkcija šest varijabli, dviju komponenti pomaka $u_{x,A}$ i $u_{y,A}$ i četiriju gradijenata pomaka $\partial u_{x,A}/\partial x$, $\partial u_{x,A}/\partial y$, $\partial u_{y,A}/\partial x$ i $\partial u_{y,A}/\partial y$. Korelacijski koeficijent uvijek poprima ekstremne vrijednosti, dakle traži se njegov minimum ili maksimum, ovisno o kojem je tipu koeficijenta riječ. Nekoliko je tipova korelacijskih koeficijenata od kojih su najvažniji CC (engl. *cross-correlation*) i SSD (engl. *sum-squared difference*) koji se temelji na izračunu zbroja kvadrata razlike vrijednosti i njime se služi algoritam optičkog sustava *Aramis* korišten u ovom istraživanju. Korelacijski kriterij optičkoga sustava *Aramis* zasniva se na minimiziranju spomenutog korelacijskog koeficijenta u okolici promatrane točke [84].

SSD korelacijskog koeficijent definiran je izrazom:

$$C = 1 - \frac{\sum_{m,n} [f(x_m, y_n) - \bar{f}] [g(x_m^*, y_n^*) - \bar{g}]}{\sqrt{\sum_{m,n} [f(x_m, y_n) - \bar{f}]^2 \sum_{m,n} [g(x_m^*, y_n^*) - \bar{g}]^2}}, \quad (5)$$

gdje su \bar{f} i \bar{g} srednje vrijednosti matrica **F** i **G**. Spomenute matrice vrijednosti su intenziteta nijansi sive boje svih piksela koji se nalaze unutar fasete u referentnoj i deformiranoj konfiguraciji, pri čemu je m broj piksela u vertikalnom smjeru, a n broj piksela u horizontalnom smjeru. Općeniti zapis matrica **F** i **G** dan je izrazima

$$\mathbf{F} = \begin{bmatrix} f_{1,1} & \cdots & f_{1,n} \\ \vdots & \ddots & \vdots \\ f_{m,1} & \cdots & f_{m,n} \end{bmatrix}, \mathbf{G} = \begin{bmatrix} g_{1,1} & \cdots & g_{1,n} \\ \vdots & \ddots & \vdots \\ g_{m,1} & \cdots & g_{m,n} \end{bmatrix}. \quad (6)$$

Postupak korelacije zapravo se svodi na usporedbu stupnja preklapanja dviju matrica [85]. Važno je napomenuti da se princip metode korelacije digitalne slike, prikazan u ovom poglavlju, temelji na lokalnom pristupu korelacije digitalne slike. Dakle, lokalni pristup obuhvaća diskretizaciju digitalnih slika podskupovima piksela koji se nazivaju fasetama pri čemu je centar fasete mjerna točka. Globalni pristup temelji se također na diskretizaciji slike podskupovima piksela, no mjerne su točke vrhovi elemenata (podskupova). Kako je u ovom istraživanju korišten optički sustav *Aramis* čiji se algoritam temelji na lokalnom pristupu korelacije digitalne slike, globalni pristup nije detaljnije prikazan.

3.7. Mjerenje optičkim sustavom *Aramis*

Aramis je beskontaktni optički 3D mjerni sustav koji se temelji na lokalnom pristupu korelacije digitalne slike. Za razliku od elektrootpornih mjernih traka ili ekstenzometara koji daju samo pojedinačne mjerne vrijednosti, *Aramis* određuje polje pomaka i raspodjelu deformacija po cijelom analiziranom području, što omogućuje bolje razumijevanje ponašanja materijala i konstrukcija tijekom opterećivanja. Primjenjuje se u analizi čvrstoće konstrukcija, za određivanje parametara materijala, validaciju i usavršavanje numeričkih proračuna, itd.




Slika 14. Optički mjerni sustav *Aramis* [86]

Kao što se vidi na slici 14., sustav se sastoji od podesivog stalka, dviju kamera, izvora svjetla i računala za obradu rezultirajućih digitalnih slika. Ako se pri mjerenju koristi jedna kamera govori se o 2D mjerenju, no ako je područje interesa trodimenzionalno mjerenje, koriste se dvije kamere (stereo). Postupak mjerenja optičkim sustavom *Aramis* može se podijeliti u nekoliko *koraka*:

- nanošenje stohastičkog uzorka na površinu mjernog objekta,
- podešavanje i kalibracija sustava za željeni mjerni volumen,
- provedba snimanja,
- pohrana i obrada digitalnih slika.

3.7.1. Nanošenje stohastičkog uzorka na površinu

Kako metoda korelacije digitalne slike zahtijeva što nepravilniju teksturu na površini mjernog objekta, potrebno je prije mjerenja adekvatno tretirati ispitne uzorke. Raster se najčešće postiže nanošenjem nereflektirajuće mat bijele boje te naknadnim nanošenjem crne boje tako da se stvore crne točkice na bijeloj podlozi. To se može postići klasičnim sprejevima ili posebnim uređajima koji mogu nanositi boju pod tlakom. Gustoća i veličina nanesenih točkica uglavnom ovisi o veličini mjernog volumena koji se analizira. Na slici 15. su primjeri stohastičkih uzoraka za različite mjerne volumene.




Slika 15. Primjeri stohastičkih uzoraka za različite mjerne volumene [86]

3.7.2. Podešavanje i kalibracija sustava

Prije početka mjerenja potrebno je podesiti optički sustav, što znači udaljenost sustava od mjernog objekta, osvjetljenje objekta i kalibraciju kamere. Kalibracija služi kako bi se podesili unutarnji i vanjski parametri kamere, te da bi se poništile sve nepravilnosti u njoj koje mogu biti uzrokovane okolinom u kojoj se obavlja mjerenje. Uzroci nepravilnosti mogu biti neprikladan prostor ispitivanja (zadimljen ili prašnjav prostor i prepreke između mjernog

objekta i kamere kao što je staklo) ili pogreške na samim kamerama i lećama (nečiste leće ili polarizacijska stakla, različita oštećenja na lećama). Tijekom mjerenja i kalibracije vrlo je važna mjerna udaljenost zbog postizanja oštre slike, a parametri kao što su udaljenost i kut između kamera (oko 25°) važni su radi bolje triangulacije točke u prostoru, pa se nakon kalibracije više ne smiju mijenjati. Mjerni sustav *Aramis* kalibrira se s pomoću odgovarajućih kalibracijskih objekata. Dvije su vrste kalibracijskih objekata – kalibracijske ploče za male mjerne volumene i kalibracijski štapovi za veće mjerne volumene. Kalibracijski objekti imaju na sebi referentne točke čije su međusobne udaljenosti poznate. Na slici 16. primjeri su kalibracijskih objekata.




Slika 16. Kalibracijski objekti [86]

U slučaju loše postavljenih kamera, naknadnih promjena udaljenosti i kuta između kamera, pogrešnog odabira kalibracijskog objekta ili pogrešno provedenog procesa kalibracije, nastaje dekalibracija sustava, što rezultira velikim odstupanjima u rezultatima mjerenja. Algoritam radi tako da se iz 2D koordinata referentne točke svake kamere triangulacijom izračunaju prostorne koordinate. Nakon toga se te prostorne koordinate *preračunaju ponovno* u 2D i uspoređuju s prvobitnim položajem, što se naziva odstupanjem referentnih točaka (engl. *reference point deviation*). Kada se taj postupak provede za sve točke snimane tijekom kalibracije i izračuna njihovo prosječno odstupanje, dobiva se pogreška kalibracije (engl. *calibration deviation*). Sustav jednadžbi triangulacije sustav je koji je predefiniran i preko kojeg se dobiva skup rješenja na osnovi čije standardne devijacije se može procijeniti je li sustav ispravno kalibriran. Na slici 17. je prikaz dijelova sustava i parametara koji se podešavaju pri kalibraciji.

Za ispravnu kalibraciju očekivana pogreška kalibracije može iznositi od 0,01 do 0,04 piksela. Kad se sustav kalibrira za određeni mjerni volumen, podaci o kalibraciji pohranjuju se u

njegovu memoriju, pa kalibraciju nije potrebno ponavljati ako se ne mijenja veličina mjernog volumena.




Slika 17. Ilustracija sustava Aramis s potrebnim parametrima za podešavanje

3.7.3. Provedba snimanja uzoraka

Kad je sustav kalibriran znači da je definirana veličina piksela, odnosno definirano je koliko piksela odgovara jednom milimetru. Nakon kalibracije sustav je spreman za mjerenje te se pozicionira ispred mjernog objekta na odgovarajuću udaljenost i, ako je potrebno, dodatno se podešavaju izvori svjetla kako bi se dobila oštra slika bez neželjenih refleksija. Neposredno prije snimanja potrebno je podesiti parametre kamere, a to znači brzinu snimanja slika i vrijeme ekspozicije. Oba parametra ovisna su o tehničkim specifikacijama kamere, ali direktno ovise i o količini svjetla na mjernom objektu.


3.7.4. Pohrana i obrada digitalnih slika

Nakon snimanja rezultirajuće digitalne slike pohranjuju se u memoriju sustava. S obzirom na to da se algoritam sustava temelji na lokalnom pristupu metode korelacije digitalne slike, digitalne slike diskretiziraju se fasetama. Veličina fasete i *korak* definiraju se softverski pri obradi digitalnih slika. Na slici 18. je primjer fasete veličine 15 x 15 piksela s *korakom* od 13 piksela, odnosno s 2 piksela preklapanja.



Slika 18. Faseta veličine 15x15, s 2 preklapajuća piksela [87]

Kako je već spomenuto, fasete se identificiraju i prate s pomoću stupnja intenziteta nijansi sive boje tijekom različitih *koraka* opterećenja. Dakle, veličina fasete direktno utječe na mjernu nesigurnost mjerenja pomaka i deformacija, što zorno prikazuje slika 19.



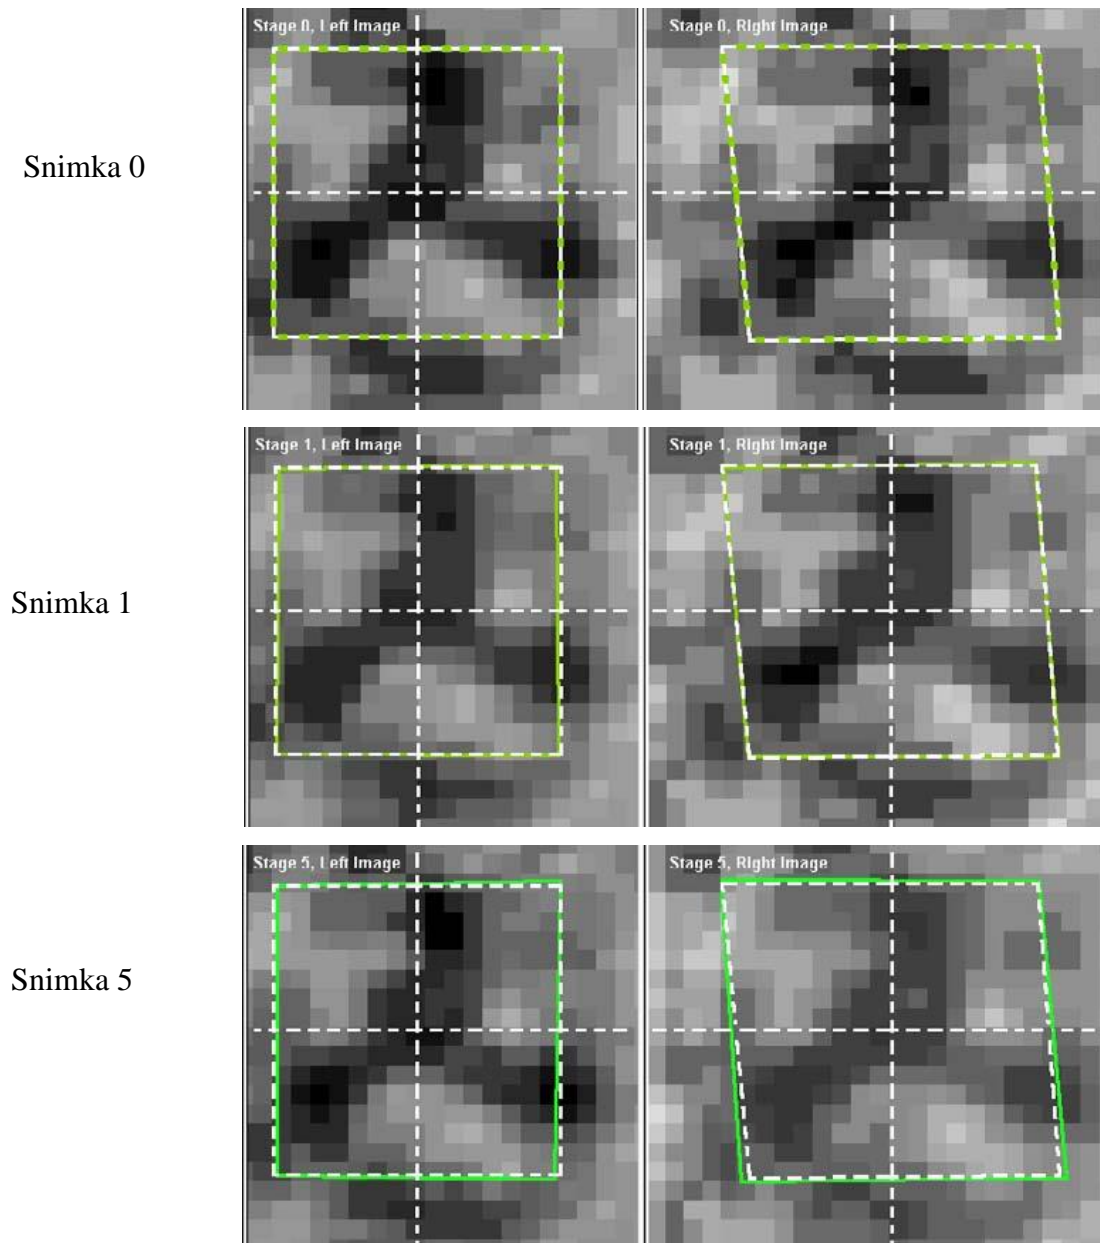
Slika 19. Ovisnost mjerne nesigurnosti pomaka i deformacija o veličini fasete [85]

Povećanje faseta ima za posljedicu smanjenje mjerne nesigurnosti mjerenja, što se vidi na slici 19., no izračun postaje računalno zahtjevniji i ne mogu se odrediti lokalne promjene – pomak i deformacija koji se pojavljuju u zonama manjima od veličine fasete. S druge strane, smanjenje veličine faseta omogućuje praćenje lokalnih promjena, vrijeme izračuna postaje kraće, a mjerna nesigurnost se povećava. Što se tiče *koraka* fasete, njegovim povećanjem smanjuje se gustoća mjernih točaka, a posljedica je kraće trajanje izračuna pomaka i deformacija, za razliku od smanjenja *koraka* fasete gdje se povećava gustoća mjernih točaka, što čini izračun računalno zahtjevnijim.

Općenito, pri primjeni korelacije digitalne slike na mjernu nesigurnost utječe nekoliko čimbenika kao što su:


- **Obilježja rastera**, u smislu veličine i jednolike raspodjele crno-bijelih točkica (mrlja) koje čine nanesenu teksturu, čime se direktno definira raspodjela intenziteta nijansi sive boje koju poprimaju pikseli.
- **Parametri analize**, kao što su kriterij korelacije, funkcije oblika implementirane u algoritam i veličina i *korak* fasete.
- **Parametri kamere**, pri čemu se misli na rezoluciju, šum i optičku distorziju.
- **Utjecaj okoline**, koji obuhvaća temperaturu, vibracije stalka, osvjetljenje itd.

Na slici 20. primjer je faseta veličine 15 x 15 piksela kroz snimke 0 – 5, za slučaj mjerenja s dvije kamere. Metoda kojom uređaj prepoznaje istu sliku u dvije kamere zove se metoda epipolarne ravnine. Snimka 0 prikazuje referentno nedeformirano stanje, snimka 1 neko deformirano međustanje, a snimka 5 konačno deformirano stanje. Isprekidana bijela linija prikazuje nedeformirano stanje kako bi se jasno istaknula razlika između fasete i deformacije. Lijeve slike snimljene su lijevom kamerom, a desne slike desnom.



Slika 20. Prikaz faseta u nekoliko koraka opterećenja za slučaj 3D mjerenja [87]

Iz kutnih točaka i središta zelene fasete prikazanih na slici 20., algoritam određuje 2D koordinate te fasete. Kako se iste fasete promatraju iz lijeve i desne kamere, upotrebom fotogrametrijskih postupaka dobiva se zajednička 3D koordinata. Nakon izračuna pomaka i deformacija dobiveni rezultat dostupan je kao 3D prikaz. Primjer raspodjele deformacija dobivenih mjerenjem optičkim sustavom *Aramis* prikazan je na slici 21.



Slika 21. Primjer izmjerenih deformacija kroz nekoliko faza vlačnog ispitivanja aluminijske epruvete [88]

Sustav može mjeriti male i velike objekte (veličine od 1 mm do 2000 mm) s istim senzorom, a deformacije koje se mogu mjeriti u rasponu su od 0,01 % do 100 %. Kao rezultat dobiva se cijelo polje pomaka i deformacija na površini mjernog objekta te je zato *Aramis* iznimno moćan alat za validaciju numeričkih proračuna.

U ovom istraživanju optički sustav *Aramis* primijenit će se tijekom *in vitro* eksperimentalnih ispitivanja životinjskih i kadaveričnih kostiju te za mjerenje pomaka i deformacija na površini kosti.

4. EKSPERIMENTALNO ISPITIVANJE

U sklopu ovog istraživanja provedena su eksperimentalna *in vitro* ispitivanja kosti kojima je svrha dobivanje što boljeg uvida u mehaničko ponašanje kosti nakon narinutoga mehaničkog opterećenja te dobivanje rezultata za pomake i deformacije koji će poslužiti za validaciju numeričkih modela. Ovo poglavlje podijeljeno je u dvije cjeline. U prvom dijelu ukratko je opisano mehaničko ispitivanje svinjskih femura savijanjem u tri točke cijelih kostiju. U drugom dijelu detaljno je opisano eksperimentalno ispitivanje koje će poslužiti za validaciju numeričkih modela mehaničkoga ponašanja svinjskih, ovčjih i kadaveričnih femura. Sva ispitivanja obavljena su na statičkoj kitalici Beta 50-5 austrijskog proizvođača Messphysik s elektromotornim pogonom i maksimalnom silom od 50 kN. Uređaj je namijenjen za vlačna, tlačna i savojna ispitivanja i njime digitalno upravlja upravljačka jedinica EDC25, njemačkog proizvođača DOLI Elektronik.

4.1. Savijanje svinjskih femura u tri točke


Svrha ovog ispitivanja jest utvrditi utječe li zamrzavanje svježih svinjskih femura na krajnji iznos sile loma pri savijanju u tri točke. Svježi svinjski femuri dobavljeni su iz klaonice unutar 24 sata od usmrćivanja. Dio tih kostiju je zamrznut, a dio je odmah podvrgnut eksperimentalnom ispitivanju. Kostu nisu dodatno očišćene od mekoga tkiva jer je svrha ovog ispitivanja bila određivanje sile loma, pri čemu vertikalni hod kitalice predstavlja izmjereni pomak. Eksperimentalni postav, u ovom slučaju to su razmak i promjer valjaka, u skladu je s literaturom [4] i prikazan je na slici 22.



Slika 22. Eksperimentalni postav za savijanje svinjskih femura u tri točke

Neposredno nakon zaprimanja kostiju njih 15 ispitano je odmah, a ostalih 15 bilo je mjesec dana zamrznuto na temperaturi od -20°C u zamrzivaču i zatim su ispitane na isti način. Kosti su prije zamrzavanja poprskane fiziološkom otopinom kako ne bi izgubile vlažnost. Zamrznute kosti su prije ispitivanja odmrzavane pet sati na sobnoj temperaturi.

Fiksirani čelični valjci promjera 16 mm, koji su poslužili kao oslonci, postavljeni su na međusobnoj udaljenosti od 84 mm, a s dodatnim valjkom s gornje strane, također promjera 16 mm opterećeni su uzorci kao što je prikazano na slici 22. Svaka kost ručno je pozicionirana na uređaju za opterećivanje, pri čemu je razmak između oslonaca bio jednak za sve kosti. Opterećenje je narinuto uz kontrolu pomaka, brzinom od 4 mm/min do loma, pri čemu je podatak o pomaku i pripadnoj sili bilježen svakih 40 ms. Na slici 23. je dijagram opterećivanja jedne kosti.



Slika 23. Dijagram sila – pomak dobiven savijanjem svinjskog femura u tri točke

Na svakoj je kosti prije ispitivanja izmjeren najmanji promjer medijalnog dijela, a nakon ispitivanja izmjerena je debljina kortikalne kosti na mjestu loma kako bi se lakše mogla interpretirati eventualna razlika u maksimalnim postignutim silama kod pojedinih kostiju. Ukupno je ispitano 30 kostiju, a rezultati ispitivanja nalaze se u sedmom poglavlju. Budući da tijekom ovakvog ispitivanja nema značajnog opterećivanja ni deformiranja trabekularne kosti,

cijeli iznos opterećenja preuzima kortikalna kost. Za ova ispitivanja izabran je svinjski femur, dijelom jer se lakše nabavlja, ali i zato što je dimenzijama kraći od ovčjega i kadaveričnoga femura. Zato što su svinjske kosti kraće, jednostavnije je svaki ispitni uzorak postaviti približno u isti položaj na stroju za opterećivanje.

4.2. Tlačno ispitivanje femura

Tlačno ispitivanje femura provedeno je na svježim svinjskim, ovčjim i kadaveričnim proksimalnim dijelovima femura. Sve su kosti prije ispitivanja podvrgnute CT-skeniranju jer se u ovom istraživanju numerički model temelji na računalnoj tomografiji. Osim toga na CT-snimkama mogu se uočiti nepravilnosti ili neka znatnija oštećenja unutar kostiju koja mogu utjecati na rezultate eksperimentalnog ispitivanja. Pri eksperimentalnom ispitivanju svakog materijala važna je adekvatna priprema ispitnih uzoraka. No kako je ovdje riječ o koštanom materijalu, priprema uzoraka još je važnija, ponajprije zbog dodatnog faktora kao što je vlažnost kosti i zbog pripreme površine uzoraka za primjenu metode korelacije digitalne slike za mjerenje pomaka i deformacija. Kao što je već prije spomenuto, djelomičan ili potpun gubitak vlažnosti može uvelike utjecati na parametre koštanog materijala [2].

4.2.1. Ispitivanje svinjskih femura

Postupak eksperimentalnog ispitivanja prikazan u ovoj cjelini primijenjen je kod sve tri vrste kosti – svinjske, ovčje i kadaverične. Cijeli postupak detaljno je objašnjen na primjeru svinjskog femura, a poslije je u kratkim crtama prikazan i za slučaj ispitivanja ovčjih i kadaveričnih femura. Dio svinjskih femura također je poslužio za preliminarna ispitivanja kako bi se definirali neki od parametara eksperimentalnog postava.

4.2.1.1 Priprema uzoraka


Kosti su neposredno nakon zaprimanja djelomično očišćene od mekog tkiva te su nakon toga stavljene u zamrzivač na temperaturu od -20°C . Nakon 10 dana izvađene su i odmrzavale su se pet sati na sobnoj temperaturi. Dodatno su očišćene od mekog tkiva kako bi ostala glatka površina na koju se može nanositi boja (slika 24.). Distalni dio femura odrezan je tračnom pilom.



Slika 24. Svinjski proksimalni dio femura očišćen od mekog tkiva

Tijekom svake od navedenih radnji kosti su povremeno ovlaživane fiziološkom otopinom kako bi zadržale vlažnost.

Kosti su s pomoću posebne naprave prikazane na slici 25, pozicionirane tako da se distalni kraj djelomično nalazio unutar metalne cijevi (kalupa) visine 50 mm, promjera 48 mm i debljine stijenke 3 mm.



Slika 25. Pozicioniranje svinjskog femura s pomoću specijalne naprave: a) postavljanje distalnog kraja kosti u cijev, b) fiksiranje distalnog kraja kosti polimetilmetakrilatom (PMMA)

Kost je pozicionirana s pomoću tri vijka, a vertikalni pomak naprave omogućio je točno podešavanje duljine distalnog kraja uronjenog u smjesu PMMA (SCS-Beracryl D-28, Suter–Kunststoffe AG, Švicarska).

Metalna cijev osigurala je precizno pozicioniranje ispitnog uzorka na uređaju za opterećivanje. Visina h označena na slici 25 b) vertikalna je udaljenost od vrha femoralne glave do gornjeg ruba metalne cijevi. Da bi se osigurala što bolja ponovljivost mjerenja, sve kosti pozicionirane su tako da je visina h jednaka za sve ispitne uzorke. Kako bi kost i dio cijevi stali u vidno polje kamere, odabrana je visina $h = 107$ mm. Za fiksiranje distalnog kraja femura u metalnoj cijevi korištena je dvokomponentna smjesa polimetilmetakrilata (PMMA). Smjesa je u tekućem stanju ulivena u metalnu cijev s poklopcem i nakon 20 minuta ispitni je uzorak odvojen od naprave za pozicioniranje i ostavljen dva sata na sobnoj temperaturi kako bi se smjesa PMMA potpuno polimerizirala.

Na površinu ispitnih uzoraka nanesen je stohastički uzorak, crno-bijeli raster izrazitoga kontrasta, kako bi se za mjerenje pomaka i deformacija mogla primijeniti metoda DIC. Zadatak rastera je da tijekom opterećivanja prati promjene oblika mjernog objekta, odnosno pomake i deformacije na njegovoj površini. Stohastički uzorak nanesen je nereflektirajućom (mat) bojom u spreju (Aqua sprej na bazi vode proizvođača Motip-dupli GmbH, Kurt Vogelsang, Njemačka), i to tako da je najprije nanesen vrlo tanki sloj bijele boje koja se sušila 30 minuta na ispitnom uzorku (slika 26. a).



Slika 26. Nanošenje stohastičkog uzorka: a) bijela boja, b) crne točkice


Bijela boja odabrana je da bi se postigao što bolji i jednoličniji kontrast, s obzirom na to da je boja površine svježe kosti vrlo neujednačena, kao što se vidi na slici 24. Nakon tankog sloja bijele nanosena je crna boja tako da su sprejom, u nekoliko prolaza, raspršene sitne točkice

boje koje stvaraju dovoljno stohastički uzorak, što osigurava pronalaženje istih faseta u objema kamerama. Postignuta veličina i gustoća crnih točkica odabrana je na osnovi slike 15. u trećem poglavlju.

Uzorci s umjetnom teksturom ostavljeni su jedan sat da se suše na sobnoj temperaturi. Kod ovakvog tretiranja ispitnih uzoraka vrlo je važno da boja dobro prione uz površinu jer bi se u protivnom mogla odvojiti i izmjereni pomaci i deformacije ne bi odgovarali onima na površini kosti. Na slici 26. b) vidi se da je raster nanesen i na metalnu čašu. Razlog je što će se taj dio također snimati kamerama te će se na osnovi izmjerenih vrijednosti pomaka na kalupu moći procijeniti je li se tijekom ispitivanja dogodio neželjeni relativni pomak naprave za pozicioniranje.


4.2.1.2 Provedba mehaničkog ispitivanja

Nakon pripreme ispitnih uzoraka slijedi mehaničko ispitivanje. U prvoj fazi odvojeno je nekoliko ispitnih uzoraka za pokusna ispitivanja koji su također pripremljeni i tretirani na ranije opisani način. Ispitni uzorci pozicionirani su na uređaj za opterećivanje (kidalici) s pomoću posebne naprave učvršćene za postolje kidalice koja, između ostalog, omogućuje kutno podešavanje ispitnih uzoraka (slika 27.).



Slika 27. Pozicioniranje ispitnog uzorka s pomoću posebne naprave za podešavanje: a) naprava za podešavanje na kidalici, b) detalj prihvata ispitnog uzorka

Kod biomehaničkih eksperimentalnih *in vitro* ispitivanja vrlo je važno pravilno prenijeti opterećenje na ispitni uzorak. Da bi se to provjerilo pripremljena su tri ispitna uzorka i provedena pokusna mjerenja s eksperimentalnim postavom prikazanim na slici 27. Opterećenje usmjereno vertikalno prema dolje prenosi se na femoralnu glavu adapterom prikazanim na slici 27 b) koji je s donje strane potpuno ravan. Posljedica takvog načina opterećivanja jest da se sila na glavu femura na početku prenosi preko jedne dodirne točke. Kako se tu pretežito nalazi spongiozna kost, tijekom opterećivanja vrlo brzo nastaje oštećenje u toj dodirnoj točki te se opterećenje ne prenosi odgovarajuće dalje na vrat i tijelo femura, nego dolazi do loma glave femura (slika 28.). Na taj se način ne dobiva realan odziv kosti na mehaničko opterećenje. Kod svih pokusnih uzoraka uočena je ista pojava, te se takav način opterećivanja pokazao iznimno lošima kod svinjskog femura.



Slika 28. Oštećenje glave femura


Iz navedenog razloga korišten je oblik dodirne površine adaptera za opterećivanje koji osigurava da se sila prenosi preko više dodirnih točaka, odnosno u idealnom slučaju preko površine kuglinog odsječka. Adapter je napravljen strojnom obradom polimerizirane smjese PMMA i s gornje strane pričvršćen je na aksijalni ležaj, kao što se vidi na slici 29. b). Ležaj omogućuje samonamještanje adaptera za prijenos opterećenja i bolje nalijezanje na femoralnu glavu. Tako je osigurano da rezultantna sila uvijek djeluje vertikalno i da se opterećenje

prenosi s glave dalje na vrat i tijelo femura, što više odgovara opterećenju kosti u ljudskom ili životinjskom skeletu.




Slika 29. Eksperimentalni postav: a) optički sustav *Aramis* i pozicionirani ispitni uzorak, b) uvećani detalj ispitnog uzorka i adaptera za prijenos opterećenja s aksijalnim ležajem

Eksperimentalni postav korišten tijekom ispitivanja svih uzoraka prikazan je na slikama 29. i 30. Ispitni uzorak je pri pozicioniranju zakrenut kao što prikazuje slika 30, tj. os trupa femura zakrenuta je za kut (inklinacije) od 7° u odnosu prema vertikalnoj osi opterećenja (kidalice), što je kod ljudskog femura prirodni položaj stajanja [50]. Kod svinjskog i ovčjeg femura spomenuti kut inklinacije mnogo manje utječe na deformiranje kosti zbog narinutog opterećenja, ponajprije zato što je vrat svinjskoga i ovčjeg femura mnogo kraći nego što je to slučaj kod ljudske bedrene kosti.



Slika 30. Položaj svinjskog femura tijekom ispitivanja

Opterećenje prikazano na slici 29. b) crvenom strelicom, narinuto je kontrolom pomaka brzinom od 2 mm/min, što je unutar raspona brzina opterećivanja najčešće korištenih u literaturi tijekom sličnih biomehaničkih ispitivanja proksimalnog femura [49]. Podatak o vertikalnom pomaku i pripadnoj sili bilježen je svakih 40 ms s pomoću upravljačke jedinice kidalice. Najprije je jedan ispitni uzorak opterećen do loma, kako bi se definirao iznos opterećenja koja ne uzrokuju trajnu deformaciju ili lom kosti. Na osnovi dobivenog dijagrama koji je prikazan na slici 31. odabrana su dva opterećenja koja odgovaraju silama od 1500 i 3000 N. Nakon definiranja svih spomenutih parametara, pristupilo se provedbi eksperimentalnog ispitivanja gdje su pomaci i deformacije određivani metodom korelacije digitalne slike, primjenom optičkog sustava *Aramis*. Za to je bilo pripremljeno i ispitano pet uzoraka koji su također opterećivani do loma, a rezultati za pomake i deformacije pri opterećenju od 1500 i 3000 N poslužili su za usporedbu s rezultatima računalnih simulacija provedenima metodom konačnih elemenata.




Slika 31. Dijagram sila – pomak dobiven opterećivanjem svinjskog femura

Ukupno je pripremljeno deset, a ispitano devet svinjskih femura, kao što se vidi u tablici 1. Na jednoj od kostiju tijekom pripreme uočeno je oštećenje na vratu femura, što je potvrđeno i CT-snimkama, tako da taj uzorak nije podvrgnut eksperimentalnom ispitivanju.

Tablica 1. Broj ispitanih uzoraka svinjskih femura

Svrha ispitivanja	Broj uzoraka
Podešavanje parametara eksperimentalnog postava	3
Definiranje iznosa opterećenja u elastičnom području	1
Primjena korelacije digitalne slike	5

Za pet svinjskih femura koji su ispitani zbog određivanja pomaka i deformacija korelacijom digitalne slike, dijagram ovisnosti sile i pomaka (vertikalnog hoda kidalice) prikazan je na slici 32. Kratica SF na slici 32. označava *svinjski femur*, a brojevi od 1 do 5 redni su broj ispitnog uzorka.



Slika 32. Dijagram sila – pomak dobiven opterećivanjem svinjskih femura

Na slici 32. vidi se da svi ispitni uzorci pokazuju linearno elastičan odziv do iznosa sile od približno 4 kN, čime je potvrđena konstatacija da pri silama od 1,5 kN i 3 kN sigurno neće nastati trajne deformacije kosti. Kod uzorka SF4 zabilježen je skokoviti pad sile s približno 3,8 kN na 1,4 kN. Razlog za to može biti samonamještanje adaptera za opterećivanje na glavi femura ili eventualna mikrooštećenja unutar kosti koja nisu zabilježena na površini na kojoj se mjere pomaci i deformacije. Budući da se do nagla promjena sile dogodila iznad 3 kN, a

ovdje se analiziraju rezultati pri silama od 1,5 kN i 3 kN, rezultati dobiveni ispitivanjem uzorka SF4 mogu se uzeti kao mjerodavni. Važno je napomenuti da su svi ispitni uzorci pucali na vratu femura.

4.2.1.3 Mjerenje pomaka i deformacija na površini kosti

Za mjerenja pomaka i deformacija na površini ispitnih uzoraka SF1 do SF5 tijekom opterećivanja, korišten je optički sustav *Aramis 4M*, prikazan na slici 29. a). Mjerenje je provedeno dvjema kamerama kako bi se mogli pratiti pomaci i deformacije na jednoj strani kosti u tri dimenzije. Sustav *Aramis 4M* opremljen je dvjema digitalnim CCD kamerama Dalsa Falcon 4M60 s frekvencijom od 60 do 480 Hz i rezolucijom 2358×1728 piksela.

Prije mjerenja podešeni su parametri optičkog sustava i provedena je kalibracija. Za mjerenje u ovom radu odabrani su parametri:


- objektiv 50 mm,
- mjerni volumen: 125 x 90 mm,
- mjerna udaljenost: 475 mm,
- međusobna udaljenost kamera: 184 mm,
- kut kamera: 25°.

Optički sustav kalibriran je kalibracijskim objektom CP20/MV90/72 prikazanim na slici 33.



Slika 33. Kalibracija optičkog sustav *Aramis*

Nakon završetka kalibracije postignuta je pogreška kalibracije od 0,019 piksela, što je unutar dopuštenog raspona (0,01 do 0,04 piksela) koji je kriterij za ispravnu kalibraciju. Što se tiče osvjetljenja, neposredno prije mjerenja neželjene refleksije uklonjene su primjenom polarizacijskih prstenova na izvorima svjetla. Pri mjerenju brzina snimanja slika je podešena na jednu sliku u sekundi (engl. *Frames per second*, FPS), a s obzirom na količinu svjetla, trajanje ekspozicije podešeno je na 56 ms. Nakon završetka mjerenja digitalne slike pohranjene su u memoriju, a poslije su diskretizirane fasetama veličine 20 x 20 piksela s četiri piksela preklapanja (slika 34 a).



Slika 34. Referentna (nedeformirana) slika uzorka SF1 s jedne od kamera: a) odabrana veličina fasete, b) referentna slika bez polja fasete, c) referentna slika s poljem fasete

Na području označenom plavom bojom na slici 34 c), bit će izračunati pomaci i deformacije na svakoj snimljenoj slici. Digitalne slike koje odgovaraju silama od 1,5 kN i 3 kN detaljno su analizirane, a rezultati za pomake i deformacije dani su u sedmom poglavlju.

4.2.2. Ispitivanje ovčjih femura

Ovčji femuri nabavljeni su u Veterinarskom fakultetu Sveučilišta u Zagrebu. Eksplantirani lijevi i desni femuri dobiveni su od ženki ovaca merino pasmine u dobi od 2 do 3 godine. Mehaničko ispitivanje ovčjih femura provedeno je analogno postupku koji je detaljno opisan na primjeru ispitivanja svinjskih femura. Šest ovčjih femura čuvano je zamrznuto 73 dana, nakon čega su kosti odmrznute i očišćene od mekog tkiva te pripremljene za ispitivanje. Priprema, kao što je prije navedeno, obuhvaća uklanjanje distalnog kraja femura, pozicioniranje i učvršćivanje ispitnog uzorka s pomoću smjese PMMA i nanošenje

stohastičkog rastera na površinu kosti (slika 35.). Ispitni uzorci pozicionirani su u metalnoj cijevi tako da visina h definirana u prethodnoj cjelini iznosi 107 mm.




Slika 35. Priprema ovčjeg femura za mehaničko ispitivanje

Pri pozicioniranju ispitnih uzoraka na kidalici (slika 36) kut inklinacije podešen je kao i kod svinjskih femura (7°).



Slika 36. Ovčji femur pozicioniran na kidalici


Opterećenje je narinuto kontrolom pomaka brzinom od 2 mm/min. i uzorci su opterećeni do loma. Jedan uzorak iskorišten je za ispitivanje utjecaja brzine opterećivanja, što je prikazano na slici 37 dijagramom sila – pomak.



Slika 37. Dijagram sila - pomak ovčjeg femura za različite brzine opterećivanja

Iz dijagrama na slici 37. vidi se da promjena brzine opterećivanja unutar raspona od 0,5 do 5 mm/min. zanemarivo utječe na rezultate eksperimentalnog ispitivanja.

Preostalih pet uzoraka (OF1 do OF5) ispitano je do loma, a dijagram sila – pomak prikazan je na slici 38.




Slika 38. Dijagram sila – pomak za ovčje femure

Kratice OF na slici 38. označava *ovčji femur*, a brojevi od 1 do 5 redni su broj ispitnog uzorka. Sile od 3 kN i 6 kN, kod kojih su svi ispitni uzorci još u elastičnom području, odabrane su za analizu pomaka i deformacija. Svi ispitni uzorci pucali su u području trupa femura. Pomaci i deformacije određeni metodom DIC prikazani su u sedmom poglavlju.


4.2.3. Ispitivanje kadaveričnih femura

Zamrznuti kadaverični femuri dobiveni su iz Zavoda za anatomiju Medicinskog fakulteta Sveučilišta u Rijeci. Zaprimiteljna su tri femura, dva od muške osobe (godiste 1929.) i jedan od ženske osobe (godiste 1926.). Uzorci su nakon 14 dana odmrznuti te su podvrgnuti postupcima pripreme i ispitivanja detaljno objašnjenima u prethodnim cjelinama. Kako kadaverične kosti dimenzijama dosta odstupaju od svinjskih i ovčjih, bilo je nekih razlika u eksperimentalnom postavu. Na ljudskom femuru mali je trohanter mnogo izraženiji i veći nego kod svinjskih i ovčjih kostiju te se nalazi niže, gledano distalno od vrata femura. Zato je kod kadaveričnih femura visina h povećana na 160 mm. Kut inklinacije ostao je isti kao i kod ispitivanja svinjskih i ovčjih femura. Kako je kod ljudskog femura promjer glave mnogo veći nego kod svinjskih i ovčjih, napravljen je dodatni adapter za opterećivanje kako bi se sila što jednoličnije prenijela na glavu femura. Eksperimentalni postav pripremljenoga kadaveričnog femura prikazan je na slici 39.



Slika 39. Ispitni uzorak kadaveričnog femura pripremljen za mehaničko ispitivanje

Ispitni uzorci postavljeni su na uređaj za opterećivanje prema slici 39. i svi su opterećeni do loma kontrolom pomaka, brzinom od 2 mm/min. Dijagram sila – pomak dobiven ispitivanjem svih uzoraka (KF1, KF2 i KF3) prikazan je na slici 40.



Slika 40. Dijagram sila – pomak dobiven opterećivanjem kadaveričnih femura

Za kadaverični femur uvedena je oznaka KF i kao takva koristit će se pri prikazivanju rezultata za pomake i deformacije u sedmom poglavlju. Na osnovi dijagrama na slici 40. odabrane su sile od 3 kN i 6 kN pri kojima se analiziraju pomaci i deformacije na površini ispitnih uzoraka. Vidi se da je ispitni uzorak KF3 po nagibu odstupa od uzoraka KF1 i KF2 i ne postiže silu od 6 kN. Razlog – uzorci KF1 i KF2 od istog su kadavera (lijevi i desni femur), a KF3 je od drugoga. Također je uočeno da uzorak KF3 ima manji promjer glave femura, manji promjer trupa, manju debljinu kortikalne kosti i nešto duži vrat.

Svi uzorci pucali su u području vrata, što je i obilježje ljudskog femura. Lom na primjeru ispitnog uzorka KF2 prikazan je na slici 41.



Slika 41. Lom ispitnog uzorka KF2

5. RAČUNALNA TOMOGRAFIJA

Danas se u medicini često koriste tehnike slojevitog snimanja jer prikazuju presjeke tijela u slojevima određene debljine. Jedna od njih je računalna tomografija (CT) na kojoj se temelji dio ove doktorske disertacije. Prvi CT-uređaj proizveli su 1972. godine Godfrey Hounsfield i Allan Cormack [89], za što su poslije dobili Nobelovu nagradu. Prvi klinički CT-skeneri postavljeni su 1974. i 1976. godine, a danas ih je u svijetu više od 30 000 instaliranih. Na slici 42. prikazan je suvremeni CT-uređaj. Magnetska rezonancija (MR) također se ubraja u tehnike slojevitog snimanja, ali nije dio ovog istraživanja. Kao što se vidi na slici 42., CT-uređaj sastoji se od velikog kućišta, stola i računalnih radnih stanica. U kućištu su rendgenske cijevi, detektori, transformatori, kolimatori i filtri.




Slika 42. CT-uređaj *Toshiba Aquilion* [90]

5.1. Princip računalne tomografije

Računalna tomografija radiološka je metoda koja se koristi kolimiranim snopom rendgenskih zraka za dobivanje slojevitog prikaza željenog objekta. Princip rada temelji se na atenuaciji ili slabljenju rendgenskih zraka prolaskom kroz snimani objekt, zbog čega dolazi do njihove apsorpcije odnosno rasipanja, što se izražava koeficijentom apsorpcije. Rendgenske zrake dolaze s rendgenskih cijevi i snage su od 30 do 50 kW, pri naponu od 140 kV. Nakon prolaska kroz objekt, oslabljeno zračenje pada na detektore. Kolimatori i filtri služe za

definiranje izgleda snopa rendgenskog zračenja i apsorbiraju niskoenergijske dijelove spektra rendgenskih zraka. Detektori mjere intenzitet oslabljenog zračenja i pretvaraju ga u električne signale proporcionalne atenuaciji snimanog objekta. Iz niza takvih projekcija koje nastaju za rotacije rendgenske cijevi i detektora, složenim matematičkim algoritmima rekonstruira se slika objekta (slika 43.).




Slika 43. Princip rada CT-uređaja [91]

Slika objekta je matrica koja se sastoji od piksela. Algoritam rekonstrukcije slike temelji se na izračunu koeficijenta atenuacije za svaki piksel kojem se dodjeljuje jedna od nijansi intenziteta sive boje. Siva skala označuje raspon nijansi između bijele i crne boje. Za računalnu tomografiju karakteristični su aksijalni presjeci koji nastaju u ravni rotacije rendgenske cijevi, pa se još koristi i naziv računalna aksijalna tomografija (engl. *Computed Axial Tomography*, CAT).


Za prvu generaciju uređaja karakteristična je kombinacija rotacije i translacije rendgenske cijevi. Skeniranje se moglo obavljati sekvencijski, tj. rotacijom rendgenske cijevi, a nakon toga translacijom stola. Ako se stol translacija kontinuirano i istodobno traje rotacija rendgenske cijevi, govori se o spiralnom ili volumetrijskom načinu snimanja koje omogućuje obradu podataka iz volumena snimanog objekta. Prednosti spiralnog skeniranja su kontinuirano prikupljanje podataka i skraćeno ukupno vrijeme skeniranja. Kod uređaja novijih generacija cijev i detektori sinkrono rotiraju oko skeniranog objekta. Ako CT-uređaj ima više

redova detektora za generiranje većeg broja slojeva po jednoj rotaciji, govori se o višeslojnom CT- uređaju (engl. *Multi Slice Computed Tomography* – MSCT). Na slici 44. prikazana je razlika u radu klasičnoga i višeslojnoga CT-uređaja.



Slika 44. a) Klasični CT-uređaj b) MSCT-uređaj

Prednost MSCT-uređaja velika je brzina skeniranja jer rotacija cijevi može trajati manje od 0,5 sekundi. Tako se može snimiti veći dio objekta u kraćem vremenu, no to direktno utječe na primljenu dozu zračenja osobe ili objekta koji se skenira. Jedna je od prednosti i vrlo dobra prostorna rezolucija koja iznosi od 15 do 30 lp/mm (engl. *line pair*, lp). Što je veća vrijednost lp/mm, to je lakše razlučiti više detalja na slici. Glavna je prednost višeslojnog CT-a dobivanje gotovo izotropnog voksel, što omogućuje rekonstrukciju slike u bilo kojoj odabranoj ravnini bez gubitka rezolucije. Naime pri CT-skeniranju veličina piksela slike obično je manja od milimetra, a debljina sloja kod skenera s jednim redom detektora obično je veća od 5 mm. U takvim slučajevima kaže se da su vokseli anizotropni, jer su u obliku četverostrane prizme kojoj je jedna dimenzija mnogo veća od ostale dvije, što je prikazano na slici 45.



Slika 45. Prikaz CT-sloja koji se sastoji od anizotropnih voksel

Tijekom CT-skeniranja treba voditi brigu o nekim parametrima kao što su:

- napon rendgenske cijevi (kV),
- jakost struje rendgenske cijevi (mA),
- elektriziranost rendgenske cijevi (mAs),
- polje gledanja (engl. *FOV- filed of view*) (mm),
- rezolucija (npr. 512 x 512 piksela),
- veličina piksela (mm),
- debljina sloja (mm),
- razmak između slojeva (mm).

Spomenuti parametri podešavaju se ovisno o svrsi i području interesa skeniranja (npr. kost, meko tkivo ili nešto treće). MSCT-uređajem može se skenirati tako da razmak između slojeva iznosi 0 mm, ili da postoji preklapanje između slojeva. Tako se dobiva mnogo više podataka i vrlo precizan volumni prikaz objekta.

5.2. Hounsfieldov broj

Slike dobivene CT-skeniranjem su u formatu DICOM (engl. *Digital Imaging and Communications in Medicine*) i svakom pikselu dodjeljuje se Hounsfieldov broj (engl. *Hounsfield unit*, HU). On je vrlo važan podatak koji je direktno vezan za stupanj atenuacije

rendgenskih zraka, a često ga se naziva i CT-brojem. Raspon CT-broja ovisi o broju bitova po pikselu, pa tako primjerice kod 12-bitne slike poprima vrijednosti od -1000 do 3095, pri čemu je vrijednost -1000 za zrak, a vrijednost 0 za vodu.

Hounsfieldov broj izražava se u relativnom omjeru prema vodi, kako bi se izbjegla njegova ovisnost o energiji rendgenskog snopa, a definira se kao

$$HU = \frac{\mu - \mu_{voda}}{\mu_{voda} - \mu_{zrak}} \times 1000, \quad (7)$$

pri čemu su μ_{voda} [m^{-1}] i μ_{zrak} [m^{-1}] linearni koeficijenti atenuacije. Linearni koeficijent atenuacije pokazuje koliko su rendgenske zrake koje padaju na detektore oslabjele prolaskom kroz neko tkivo [92]. Neke uobičajene vrijednosti Hounsfieldova broja nalaze se u tablici 2.


Tablica 2. Uobičajene vrijednosti Hounsfieldova broja

Medij (tkivo)	HU
Zrak	-1000
Meko tkivo	100 do 300
Voda	0
Krv	30 do 45
Mišić	40
Trabeukalna kost	do 700
Kortikalna kost	do 3000

5.3. Artefakti


Pri primjeni računalne tomografije moguća je pojava određenih artefakata koji se mogu podijeliti na artefakte koji nastaju na fizikalnim osnovama, artefakte vezane za pacijente (objekt) i artefakte vezane za uređaj [93].

Kod artefakata vezanih za pacijente misli se u prvom redu na neželjeno pomicanje pacijenta ili snimanog objekta pri CT-skeniranju. Metalni ukrasi i eventualno neki ugrađeni implantati također mogu stvarati dodatne artefakte, kao što se vidi na slici 46.



Slika 46. Artefakti na CT- snimci osobe koja ima ugrađen umjetni kuk

Što se tiče artefakata vezanih za uređaj, uglavnom se misli na kalibraciju CT-uređaja. Primjerice, ako je neki od detektora dekalibriran, može se pojaviti tzv. cirkularni artefakt (engl. *Ring artefact*) koji se manifestira u obliku koncentričnih kružnica iznad skeniranog dijela. Primjer takvog artefakta prikazan je na slici 47.



Slika 47. Primjer CT snimke s artefaktom a) i s uklonjenim artefaktom b) [94]

Problem se rješava ponovnom kalibracijom i s vremena na vrijeme zamjenom detektora. Zbog rotacije detektora i cijevi, oko skeniranog objekta moguća je pojava artefakta koničnog snopa (engl. *Cone beam artefact*). Ovaj artefakt može se eliminirati odgovarajućim adaptivnim filtracijskim tehnikama [93]. Pri skeniranju bez preklapanja slojeva s prevelikim razmakom između slojeva pojavljuje se artefakt stepenica (engl. *stair-step artifacts*).

Što se tiče artefakata na fizikalnim osnovama, jedan od važnijih je *Beam hardening*. Kako se snop rendgenskih zraka sastoji od individualnih fotona različite energije, prolaskom kroz snimani objekt raste njegova energija zato što se fotoni niže energije apsorbiraju mnogo brže

od fotona više energije i tada se kaže da snop postaje *tvrđi* [93]. Posljedica je stvaranje tamnih i svijetlih pruga između dvaju objekata s visokim stupnjem atenuacije, kao što su kost ili metal. *Beam hardenig* artefakti smanjuju se primjenom odgovarajućih filtara i posebnim softverima za korekciju.

U istoj su skupini i artefakti parcijalnog volumnog efekta (engl. *Partial volume effect*). Ovi artefakti pojavljuju se u području nagle promjene Hounsfieldova broja, tj. na prijelazima s velikom razlikom u gustoći tkiva. Unutar istog vokselu susreću se rubovi više različitih tkiva i pri rekonstrukciji računa se srednja HU vrijednost tog vokselu. Te pogreške i artefakti mogu se smanjiti ili izbjeći povećanjem rezolucije, tj. korištenjem tanjih slojeva tijekom skeniranja.

5.4. Određivanje gustoće kosti

Gustoća kosti definira se kao masa koštanog tkiva koje se nalazi u jedinici volumena kosti, a izražava se u g/cm^3 . Više je pristupa kako izmjeriti gustoću kosti, no najvažniji se temelje na rendgenskom i gama-zračenju. Jedna od metoda koja se temelji na tom pristupu jest denzitometrija kojom se neinvazivno ne mjeri direktno gustoća kostiju, nego mineralna gustoća kostiju (engl. *BMD – Bone mineral density*). Kako sam naziv govori, mineralna gustoća kosti pokazuje količinu minerala, tj. kalcija koja se nalazi u kosti. Među ostalim, mineralna gustoća kosti glavni je indikator boluje li osoba od osteoporoze i postoji li povećan rizik od loma kostiju. Najvažnije regije za mjerenje mineralne gustoće kosti su vrat bedrene kosti, lumbalna kralježnica i kosti podlaktice, jer su to lokalizacije najvećeg rizika za frakturu na mjestima gdje je masa koštanog tkiva mala.

Neke od važnijih metoda mjerenja mineralne gustoće kosti su:

- ultrazvuk,
- SXA (engl. *Single Energy X-ray Absorptiometry*),
- DEXA (engl. *Dual Energy X-ray Absorptiometry*),
- PDXA (engl. *Peripheral Dual Energy X-ray Absorptiometry*),
- RA (engl. *Radiographic Absorimetry*),
- MR,
- CT.

U nastavku će nešto više biti rečeno o metodi DEXA jer je najrašireniji oblik mjerenja mineralne gustoće kosti u medicini, te o mjerenju gustoće CT-om jer se na računalnoj tomografiji temelji numerički model kosti razvijen u sklopu ovog istraživanja.

5.4.1. Dvoenergijska rendgenska denzitometrija (DEXA)


Osnova za mjerenja gustoće kosti s dvoenergijskim rendgenskim izvorom zračenja jest razlika u apsorpciji fotona u kosti i u mekom tkivu. Matematičkim algoritmom, koji opisuje apsorpciju dviju energija u sustavu koji se sastoji od dviju komponenti, mekog tkiva i kosti, dobivaju se vrijednosti mase kosti i mekog tkiva u g/cm^2 . Atenuacija zračenja proporcionalna je koštanoj masi. Ako se oduzme količina zračenja koja je prošla kroz meko tkivo od ukupne količine zračenja koja je prošla kroz tijelo, ono što preostaje jest mineralna gustoća kosti (BMD). Važno je uočiti da ovaj način ne daje pravu koštanu gustoću, nego takozvanu površinsku gustoću kosti izraženu u g/cm^2 , koja je dijelom ovisna o volumenu kosti. Prednosti metode su velika preciznost i nisko radijacijsko opterećenje koje iznosi otprilike 10 % od doze koju osoba primi pri rendgenskom snimanju pluća.

5.4.2. Određivanje gustoće kostiju računalnom tomografijom

Računalna tomografija omogućuje neinvazivno trodimenzionalno ili volumetrijsko mjerenje gustoće kosti (g/cm^3). Princip se temelji na povezivanju Hounsfieldova broja ili koeficijenta atenuacije rendgenskih zraka s mineralnom gustoćom, koristeći se odgovarajućim kalibracijskim protokolom. Glavna je prednost ove metode dobivanje volumetrijske mineralne gustoće, a nedostatak je općenito visoka razina zračenja CT-uređaja.


5.4.2.1 Radiološka gustoća kosti

Radiološka gustoća kostiju ρ_{QCT} (engl. *Radiological density*) zapravo je volumetrijska mineralna gustoća koja se najčešće izražava u miligramima hidroksiapatita $\text{Ca}_{10}(\text{PO}_4)_6(\text{OH})_2$ po kubnom centimetru kosti [mgHA/cm^3]. Kako se zasniva na atenuaciji rendgenskih zraka CT-uređaja, radiološku gustoću potrebno je izračunati na temelju izmjerena Hounsfieldova broja. Poveznica se ostvaruje CT-skeniranjem kalibracijskog fantoma za gustoću kosti prikazanog na slici 48. zajedno s koštanim tkivom koje se analizira. Opće je poznato da je veza između radiološke gustoće kosti i Hounsfieldova broja linearna i individualna za svaki CT-uređaj [48, 49, 50, 69, 71].



Slika 48. Primjeri kalibracijskih fantoma u kojima se nalaze mediji ekvivalentni koštanom tkivu. a) B-MAS 200 (Kyoto-Kagaku Co. Ltd., Kyoto, Japan), b) QRM-EDP fantom (QRM GmbH, Njemačka) i c) QRM-BDC fantom (QRM GmbH, Njemačka)

Primjer određivanja veze između radiološke gustoće i CT-broja prikazan je na slici 49.



Slika 49. Primjer dijagrama koji pokazuje vezu između volumetrijske mineralne gustoće kosti i Hounsfieldova broja [50]

5.4.2.2 Gustoća koštanog pepela

Gustoća koštanog pepela ρ_{ash} (engl. *Ash density*) također je indikator mineralnog sastava unutar koštanoga tkiva. Mjerenje gustoće koštanog pepela nešto je složenije, a standardna procedura zahtijeva [72]:

- izradu malih cilindričnih uzoraka (valjčića) od kostiju koji moraju biti vrlo precizni kako bi se mogao što točnije izračunati volumen svakog uzorka,
- precizno mjerenje svakog uzorka i izračun volumena uzorka (ukupni volumen koji uključuje koštano tkivo i pore unutar koštanog tkiva),
- reduciranje koštanih uzoraka na koštani pepeo, što se postiže zagrijavanjem uzoraka na 650°C u posebnim pećima, držanjem 24 sata na toj temperaturi te nakon toga hlađenjem na sobnoj temperaturi u trajanju od 24 sata,
- mjerenje mase koštanog pepela.

Omjerom izmjerene mase nakon zagrijavanja i volumena izmjenjenog prije zagrijavanja, dobiva se gustoća koštanog pepela. Temperatura od 650°C odabrana je na osnovi istraživanja [73] koje je pokazalo da nakon zagrijavanja na spomenutu temperaturu i hlađenja na sobnoj temperaturi ostaje samo koštani mineral. Kako na kraju ostaje samo mineral, u literaturi se često radiološka gustoća kosti i gustoća koštanog pepela međusobno izjednačavaju [73]. U novijim istraživanjima uvedene su neke korekcijske jednadžbe, ovisno o tipu kalibracijskog fantoma, koje povezuju ρ_{ash} i ρ_{QCT} [73].

5.4.2.3 Prividna gustoća kosti

Prividna gustoća kosti ρ_{app} (engl. *Apparent bone density*) definirana je kao omjer mase vlažnog uzorka kosti (valjčića) i ukupnog volumena tog uzorka koji uključuje koštano tkivo i unutrašnje pore. Gustoća koštanog pepela i prividna gustoća kosti vrlo su važne veličine jer se na njima temelji većina konstitutivnih zakona koji se baziraju na računalnoj tomografiji. Za određivanje prividne gustoće kosti postoji također procedura koja je navedena u literaturi [67]. Slično kao i pri mjerenju gustoće koštanoga pepela, mjerenje gustoće obavlja se na malim uzorcima u obliku valjčića i u prvom koraku mjere se dimenzije tih uzoraka. Mjerenje promjera i duljine ponavlja se šest puta na svakom uzorku i uzimaju se srednje vrijednosti na osnovi kojih se računa volumen uzoraka. Kao što je prije navedeno, volumen uključuje koštano tkivo i unutrašnje pore. Svaki uzorak se nakon toga ispire tri puta po 10 minuta u ultrazvučnoj kupki zbog skidanja koštane srži. Nakon toga se zračnim mlazom jednu minutu uklanja višak vlage iz prostora gdje se nalazila srž. Nakon toga uzorak se postavlja na

specijalnu vagu i određuje se masa. Isušivanje zrakom i vaganje ponavljaju se tako dugo dok razlika između dvaju uzastopnih mjerenja mase nije manja od 0,5 %. Ta masa podijeljena s volumenom, određenim na početku prividna je gustoća ρ_{app} . Prividna gustoća kosti povezana je s gustoćom koštanog pepela. Iz literature je poznato da je ta veza linearna [50].

6. NUMERIČKI MODEL BAZIRAN NA RAČUNALNOJ TOMOGRAFIJI

U ovom poglavlju detaljno je objašnjen postupak kreiranja numeričkog modela kosti. Numeričko modeliranje provodi se metodom konačnih elemenata, a model se bazira na računalnoj tomografiji. Pritom se na razini jednoga konačnog elementa pretpostavlja da je kost elastičan homogeni izotropni materijal. U mreži konačnih elemenata modul elastičnosti varira s gustoćom kosti, tako da je cijela kost modelirana kao nehomogeni materijal. Numerički su modelirani svinjski, ovčji i kadaverični femuri. Računalne simulacije provedene su u programskom paketu Abaqus v6.11, a obrada CT-podataka, generiranje geometrije i definiranje materijalnih svojstava obavljeno je u programskom paketu Mimics (Mimics Innovation Suite Research Edition 17.0.0.435, Materialise, Leuven, Belgija).

6.1. Provedba CT skeniranja kosti

Sve kosti koje su numerički modelirane i eksperimentalno ispitane prije toga su podvrgnute CT-skeniranju. Kosti su skenirane na uređaju Toshiba Aquilion MSCT koji se nalazi u sklopu KB-a Merkur, Zagreb. Na slici 50. prikazan je primjer skeniranja ovčjeg femura ispod kojeg se nalazi kalibracijski fantom.



Slika 50. Skeniranje ovčjeg femura na uređaju Toshiba Aquilion MSCT

Kalibracijski fantom potreban je za određivanje gustoće kosti, što je poslije detaljnije objašnjeno. Neposredno prije CT-snimanja, parametri uređaja podešeni su na uobičajene za skeniranje kostiju. Snimanje je obavljeno pri sobnoj temperaturi, u spiralnom modu s međusobnim preklapanjem slojeva, a ostali parametri korišteni tijekom CT-skeniranja nalaze se u tablici 3.

Tablica 3. Parametri korišteni tijekom CT-skeniranja

Parametar	Vrijednost
Napon rendgenske cijevi	135 kV
Jakost struje rendgenske cijevi	250 mA
Rezolucija	512 x 512 piksela
Veličina piksela	0,530 mm
Debljina sloja	0,5 mm


6.2. Rekonstrukcija geometrije

Izlazni podaci iz CT-uređaja digitalne su slike u formatu DICOM te su njihovom trodimenzionalnom rekonstrukcijom generirani 3D CAD modeli kostiju. U prvoj fazi učitani su podaci DICOM, što je s obzirom na parametre u tablici 3. značilo od 600 do 1100 CT-slojeva po jednoj kosti (tablica 4.).

Tablica 4. Približan broj CT-slojeva generiran za pojedinu grupu kosti

Grupa kosti	Približan broj CT-slojeva
Svinjski femuri	600
Ovčji femuri	700
Kadaverični femuri	1100


Određene su rubne vrijednosti Hounsfieldova broja zbog separiranja koštanog tkiva na CT-snimkama. Ovaj postupak definiranja rubnih vrijednosti toga broja poznat je pod nazivom *Thresholding*. Na osnovi izmjera Hounsfieldova broja prikazanih na slici 51. za svinjske kosti odabran je interval od 120 do 2490 HU-a.



Slika 51. CT-snimka svinjskog femura i raspodjela Hounsfieldova broja na kortikalnom i trabekularnom dijelu kosti

Dijagram na slici 51. pokazuje raspodjelu HU-a duž linija koje su prikazane na CT-snimci. Vidi se je da je raspodjela Hounsfieldova broja mnogo nepravilnija kod trabekularne kosti te je uočljiv pad vrijednosti HU-a gledajući od proksimalnog dijela femura prema medijalnom dijelu, što prikazuju zelena i žuta linija na slici 51. Također se uočava da debljina kortikalne kosti nije konstantna na medijalnom dijelu, što se može vidjeti iz same snimke i iz dijagrama prikazanog crvenom bojom. U sljedećem koraku se, na osnovi odabranog intervala HU-a, definira maska koja će poslužiti kao baza za dobivanje trodimenzionalnog modela femura. Maska za svinjski femur nalazi se na slici 52. a). Nakon njezina definiranja potrebno je precizno definirati rubove i izostaviti okolne piksele koji ne predstavljaju koštano tkivo. Primjenom dodatnih filtara maska je zaglađena tako da se izbjegne efekt parcijalnog volumena.

Distalni dio 3D modela kosti odrezan je tako da dimenzijama odgovara stvarnoj eksperimentalno ispitanoj kosti. Cijeli postupak proveden je za sve svinjske, ovčje i kadaverične femure, pri čemu je postojala razlika u definiranju raspona Hounsfieldova broja. Razlog tomu su razlike u mikrostrukтури i gustoći pojedinih grupa kostiju, kako u kortikalnom tako i u trabekularnom dijelu kosti, što je detaljnije objašnjeno u drugom poglavlju. Raspon vrijednosti HU-a odabran za pojedine grupe kostiju nalazi se u tablici 5.



Slika 52. Postupak generiranja 3D modela: a) određivanje maske na jednome od slojeva b) filtriranje neželjenih okolnih piksela i definiranje rubova, c) 3D model

Tablica 5. Rasponi Hounsfieldova broja korišteni pri definiranju maske


Grupa kosti	Raspon Hounsfieldova broja
Svinjski femuri	120 HU – 2490 HU
Ovčji femuri	90 HU – 2543 HU
Kadaverični femuri	50 HU – 2420 HU

Svi kreirani 3D modeli kosti eksportirani su u programski paket *Abaqus*.

6.3. Mreža konačnih elemenata

U ovom radu korišteni su 3D konačni elementi koji se inače koriste kada je geometrija ili opterećenje prekompleksno da bi se problem rješavao nekim drugim tipom elemenata s manje prostornih dimenzija. Ako se numerički model kosti bazira na računalnoj tomografiji, mogu se primijeniti dvije metode umrežavanja. Prva je direktna metoda kojom se CT-om generirani vokseli pretvaraju u 3D heksaedarske konačne elemente (engl. *Voxel based mesh*), i to tako da je jedan voksel jedan konačni element (slika 53.). Nedostaci takvog pristupa mogu biti problemi s rubnim elementima. Ako je rezolucija preniska, može se pojaviti nedostatak broja


elemenata po debljini kosti, a može se stvoriti i prevelik broj elemenata ako je rezolucija previsoka, što analizu može učiniti računalno vrlo skupom.



Slika 53. Mreža heksaedarskih konačnih elemenata dobivena direktnim pretvaranjem vokselu u konačne elemente (*Voxel based mesh*) na primjeru svinjskog femura

Druga metoda temelji se na prvobitnoj rekonstrukciji, na osnovi koje se generira CAD model kosti koji se nakon toga diskretizira tetraedarskim ili heksaedarskim konačnim elementima. Kod ove metode jednostavnija je kontrola gustoće mreže na pojedinim dijelovima kosti, čime se direktno utječe na vrijeme trajanja proračuna. Ova metoda također je prikladnija za dobivanje kontinuiranog polja pomaka i deformacija jer prvobitno generiranje CAD modela iz CT-a kosti podrazumijeva korištenje raznih interpolacijskih funkcija koje zaglađuju nepravilne dijelove geometrije. Kako je kost izrazito nepravilne geometrije, modeli u ovom istraživanju diskretizirani su tetraedarskim konačnim elementima drugoga reda (slika 54.). Tetraedarski element drugoga reda ima 10 čvorova i 30 stupnjeva slobode, a polje pomaka mu je opisano potpunim polinomom drugog stupnja, što znači da može opisati linearno polje deformacija i naprezanja [95]. Diskretizacija spomenutim konačnim elementima uobičajena je pri numeričkom modeliranju mehaničkog ponašanja proksimalnog femura [96].

Analiza konvergencije rješenja provedena je za sve tri grupe kostiju svinjskih, ovčjih i kadaveričnih femura, pri čemu je korišten linearno-elastičan homogeni numerički model s izotropnim svojstvima. Ispitana je konvergencija pomaka za osam različitih gustoća mreže, a rezultati su u tablici 6. i na slici 55. Numerički model (materijalni model, opterećenje, rubni uvjeti) za koji su u tablici 6. prikazani rezultati, detaljnije je opisan u tekstu koji slijedi.




Slika 54. Mreža konačnih elemenata dobivena umrežavanjem CAD modela svinjskog femura

Tablica 6. Ispitivanje konvergencije modela svinjske kosti

Gustoća mreže	Tip elemenata	Broj elemenata	Broj čvorova	Maksimalni pomak
s = 1	C3D10	318 987	480 699	0,8695
s = 1,5	C3D10	142 881	219 265	0,8694
s = 2	C3D10	78 055	122 859	0,8690
s = 3	C3D10	42 168	67 255	0,8682
s = 4	C3D10	29 298	46 912	0,8671
s = 6	C3D10	20 128	32 377	0,866
s = 10	C3D10	15 661	24 986	0,8651
s = 15	C3D10	13 032	21 010	0,8551


s – globalni stupanj gustoće mreže konačnih elemenata (engl. *Seed*)

Konvergencija rješenja ispitana je za sve grupe kostiju koje su numerički modelirane. Na taj način je od svake grupe izabran jedan model na kojem je ispitana konvergencija te je na osnovi toga odabrana gustoća mreže koja je korištena pri modeliranju ostalih femura iz te grupe. Tako je za modele svinjskih femura na osnovi tablice 6. i dijagrama na slici 55. odabrana mreža $s = 2$ koja, ovisno o modelu, sadržava od 70 000 do 80 000 konačnih elemenata. Za ovčje femure zaključak je bio sličan, te je za daljnju analizu odabrana mreža koja sadržava od 80 000 do 100 000 elemenata. Kod kadaveričnih kostiju modeli su sadržavali između 160 000 i 200 000 elemenata.




Slika 55. Konvergencija pomaka za model svinjske kosti

Dijagrami konvergencije pomaka za model ovčje i kadaverične kosti prikazani su na slikama 56. i 57.



Slika 56. Konvergencija pomaka za model ovčje kosti



Slika 57. Konvergencija pomaka za model kadaverične kosti

Nakon definiranja mreže konačnih elemenata pristupilo se definiranju materijalnog modela. Valja napomenuti da je konvergencija ispitana na modelima kostiju kojima su svim konačnim elementima dodijeljena ista mehanička svojstva, a odabrana mreža korištena je i za model kostiju gdje u mreži konačnih elemenata modul elastičnosti varira s gustoćom kosti tako da je cijela kost modelirana kao nehomogeni materijal.

6.4. Materijalni model

U literaturi se kost često navodi kao ortotropni materijal [76, 77]. Ortotropni materijal je specifičan slučaj anizotropnog materijala koji ima tri međusobno okomite ravnine elastične simetrije. Iz literature je poznato da, ako se pri numeričkom modeliranju cijela kost modelira kao nehomogeni materijal, na temelju podataka iz računalne tomografije dovoljno je kost na razini jednoga konačnog elementa modelirati kao izotropno elastičan materijal [76], a korištenje ortotropnog materijalnog modela zanemarivo utječe na krajnje rezultate. Dodatni je problem što je vrlo teško definirati osi ortotropije na trabekularnoj kosti jer se sastoji od koštanih gredica i šupljina. U ovom istraživanju kost je na razini konačnog elementa modelirana kao linearno elastičan materijal s izotropnim svojstvima, dok u mreži konačnih elemenata modul elastičnosti varira s gustoćom kosti, tako da je cijela kost modelirana kao

nehomogeni materijal. U tekstu koji slijedi ovakav model naziva se nehomogeni numerički model kosti.

6.4.1. Nehomogeni numerički model kosti

S obzirom na to da je koštano tkivo vrlo složene građe te kako unutar samih kostiju postoje velike promjene u gustoći, pri numeričkom modeliranju metodom konačnih elemenata vrlo je važno kost modelirati kao nehomogeni materijal. Kako se u ovom istraživanju nehomogeni numerički model temelji na računalnoj tomografiji, definiranje samog modela može se podijeliti u četiri faze:

- provedba CT-skeniranja kosti zajedno s kalibracijskim fantomom za gustoću kosti,
- povezivanje Hounsfieldova broja s gustoćom kosti,
- povezivanje gustoće kosti i modula elastičnosti,
- preslikavanje parametara materijala na mrežu konačnih elemenata.


6.4.1.1 Povezivanje Hounsfieldova broja s gustoćom kosti

Parametri skeniranja navedeni su u poglavlju 6.1. Na slici 58. vidi se da je pri skeniranju zajedno s kostima skeniran i kalibracijski fantom koji je poslužio za povezivanje Hounsfieldova broja s volumetrijskom mineralnom gustoćom kosti (ρ_{QCT}). Kad se spominje izračun gustoće kosti, u ovom kontekstu misli se na gustoću kosti svakoga pojedinog vokselu koji čini geometriju kosti.



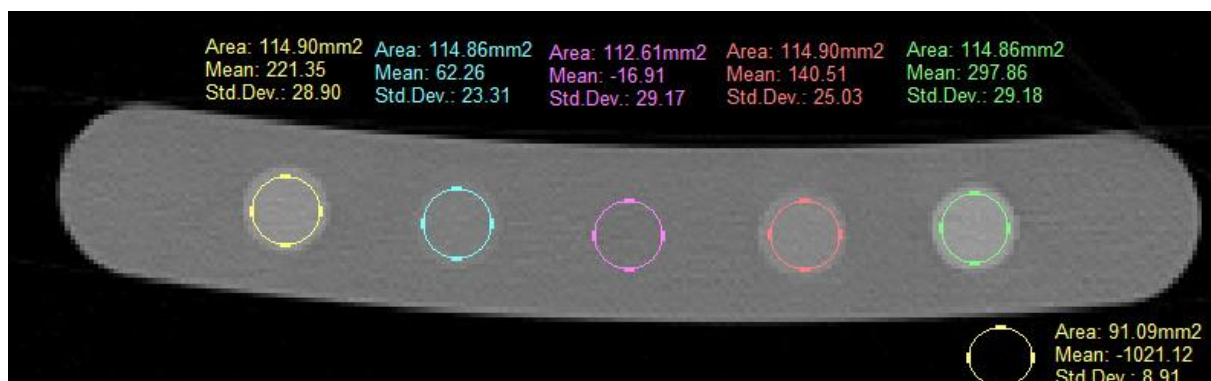
Slika 58. CT-skeniranje ovčjeg femura zajedno s kalibracijskim fantomom za gustoću kosti

Kalibracijski fantom B-MAS 200 korišten u ovim istraživanjima prikazan je na slici 59., a sastoji se od pet cilindričnih spremnika u kojima se nalaze mediji različite gustoće, ekvivalentni koštanom mineralu (hidroksiapatit $\text{Ca}_{10}\text{PO}_4(\text{OH})_2$).



Slika 59. Kalibracijski fantom za gustoću kosti B-MAS 200 (Kyoto-Kagaku Co. Ltd., Kyoto, Japan)

Za povezivanje Hounsfieldova broja i volumetrijske mineralne gustoće kosti potrebno je na CT-snimkama očitati srednju vrijednost toga broja u pojedinim spremnicima. Kako je mineralna gustoća svakog spremnika poznata, na osnovi očitanih srednjih vrijednosti podataka za HU dobivena je linearna veza između volumetrijske mineralne (radiološke) gustoće i Hounsfieldova broja, što je u skladu s literaturom [50]. Na slici 60. i u tablici 7. pokazani su podaci dobiveni CT-skeniranjem svinjskog femura zajedno s kalibracijskim fantomom.



Slika 60. Mjerenje srednje vrijednosti Hounsfieldova broja na CT-snimci

Tablica 7. Izmjerene vrijednosti za HU i podaci o gustoći kalibracijskog fantoma


Spremnik	H4	H2	H1	H3	H5
HU	221,35 (SD 28,9)	62,26 (SD 23,31)	-16,91 (SD 29,17)	140,51 (SD 25,03)	297,86 (SD 29,18)
ρ_{QCT} mgHA/cm ³	150	50	0	100	200

SD – standardna devijacija

Na osnovi podataka iz tablice linearnom interpolacijom dobiven je izraz:

$$\rho_{\text{QCT}} = 0,654 \cdot \text{HU} + 7,234, \quad (R^2 = 0,999) \quad (8)$$

koji je dijagramski prikazan na slici 61.



Slika 61. Veza volumetrijske mineralne gustoće kosti i Hounsfieldova broja za svinjski femur

Opisani kalibracijski postupak proveden je skeniranjem svih svježih kostiju koje su mehanički ispitane i numerički modelirane u sklopu ovoga doktorskog rada. Potrebno je napomenuti da je ta veza drukčija za svaki CT-uređaj te se izraz (8) može primijeniti isključivo za izračun radiološke gustoće samo te kosti, odnosno skenirane grupe kostiju. Kako su sve kosti unutar pojedinih grupa skenirane istim parametrima i u kratkom vremenskom razdoblju, nisu uočene velike razlike u dobivenim $\rho_{\text{QCT}} \rightarrow \text{HU}$ relacijama. Razlike su jedino uočene između pojedinih grupa kostiju, no može se pretpostaviti da su posljedica kalibracije unutarnjih parametara CT-uređaja između skeniranja pojedinih grupa kostiju. Zato je vrlo važno da se tijekom svakog CT-snimanja kosti u svrhu određivanja gustoće, paralelno skenira i kalibracijski fantom te da se dobivene relacije ($\rho_{\text{QCT}} \rightarrow \text{HU}$) ne generaliziraju.

U tablici 8. usporedene su dobivene $\rho_{\text{QCT}} \rightarrow \text{HU}$ relacije za svinjske, ovčje i kadaverične kosti.

Tablica 8. $\rho_{\text{QCT}} \rightarrow \text{HU}$ relacija za svinjske, ovčje i kadaverične kosti

$\rho_{\text{QCT}} \rightarrow \text{HU}$	Grupa kosti
$\rho_{\text{QCT}} = 0,654 \cdot \text{HU} + 0,7234, (R^2 = 0,999)$	Svinjski femur
$\rho_{\text{QCT}} = 0,666 \cdot \text{HU} + 11,98, (R^2 = 0,997)$	Ovčji femur
$\rho_{\text{QCT}} = 0,602 \cdot \text{HU} + 16,19, (R^2 = 0,999)$	Kadaverični femur

Nakon određivanja volumetrijske mineralne gustoće potrebno je odrediti poveznicu s gustoćom koštanog pepela i prividnom gustoćom jer se relacije gustoća – modul elastičnosti za konstitutivni model temelje na prividnoj gustoći, ili u nekim slučajevima na gustoći koštanog pepela. U literaturi se navode dva najčešće korištena pristupa. U prvom pristupu izjednačava se radiološka gustoća kosti s gustoćom koštanog pepela

$$\rho_{\text{QCT}} = \rho_{\text{ash}} \quad (9)$$

Ovaj izraz ima dva ograničenja. Jedno je vezano za odstupanje koje se pojavljuje kod graničnih vrijednosti gustoće kortikalne i trabekularne kosti, a drugo s korištenjem kalibracijskih fantoma za gustoću kosti. Naime, fantom ne može potpuno oponašati koštani materijal, uglavnom zbog razlike u građi mineralne faze koja kod fantoma ipak nije identična onoj u pravoj kosti. Osim toga, medij u fantomu je homogen, a kost je izrazito nehomogena pri prostornoj rezoluciji CT-uređaja. Drugi pristup temelji se na izrazima koji su tzv. korekcijske jednadžbe koje povezuju radiološku gustoću s gustoćom koštanog pepela (ρ_{ash}). Korekcijski izraz korišten u ovom istraživanju preuzet je iz literature [73] i vrijedi za fantom u kojem su umetci od kalcijeva hidroksiapatita, a glasi

$$\rho_{\text{QCT}} = 1,14 \cdot \rho_{\text{ash}} - 0,09 \quad (10)$$

Gustoća koštanog pepela može se preračunati u prividnu gustoću kosti (ρ_{app}). Opće je prihvaćeno da ta veza glasi [73]

$$\frac{\rho_{ash}}{\rho_{app}} = 0,6. \quad (11)$$


Izraz (11) vrijedi za cijelo područje gustoće te je na osnovi njega rađena konverzija iz ρ_{ash} u ρ_{app} u ovom istraživanju. Nakon ovih izraza za izračunavanje gustoće kosti na temelju HU-a, potrebno je definirati izraz koji povezuje gustoću kosti i modul elastičnosti.

6.4.1.2 Povezivanje gustoće kosti i modula elastičnosti

Poznato je da modul elastičnosti ovisi o gustoći kosti, ali i da ta ovisnost nije jednoznačna. Najčešći oblik veze gustoće kosti i modula elastičnosti je eksponencijalna funkcija [64]:

$$E = a \cdot \rho^b, \quad (12)$$

pri čemu gustoća kosti ρ može imati ulogu prividne gustoće kosti (ρ_{app}) ili gustoće koštanog pepela (ρ_{ash}). Parametri a i b bezdimenzijski su parametri koji se određuju eksperimentalno. Izraz (12) ponajviše ovisi o vrsti kosti koja se modelira, njezinoj anatomskoj lokaciji, području gustoće (trabekularna ili kortikalna kost) i vrsti opterećenja. Pravilan odabir relacije gustoća – modul elastičnosti, jedan je od najosjetljivijih koraka u definiranju numeričkog modela mehaničkog ponašanja kosti. U literaturi je dostupan velik broj spomenutih relacija, no većina je ograničena na proksimalni dio ljudskog femura te je upitna primjenjivost na životinjske kosti. Do tih relacija dolazi se eksperimentalnim ispitivanjem vrlo malih uzoraka kostiju koje su najčešće tlačno opterećivane, pri čemu se modul elastičnosti određuje s pomoću ultrazvučnih tehnika, nanoutiskivanjem ili kao nagib krivulje naprezanje – deformacija [36, 41, 42]. Na slici 62. dijagramski je prikaz nekoliko često korištenih relacija gustoća – modul elastičnosti.



Slika 62. Relacije gustoća – modul elastičnosti često korištene u literaturi [46]

Na slici 62. vidi se da neke od relacija vrijede samo za trabekularnu kost, neke samo za kortikalnu kost, a neke za cijelo područje gustoće. Također valja razmotriti mogućnost ekstrapoliranja relacija koje su za područje smanjene gustoće kosti, na cijelo područje gustoće. Relacije najviše zatupljene u literaturi su

$$E = 6,85 \cdot \rho_{app}^{1,49} \text{ (Morgan, 2003),} \quad (13)$$

$$E = 10,5 \cdot \rho_{ash}^{2,57} \text{ (Keller, 1994),} \quad (14)$$


$$E = 3,891 \cdot \rho_{app}^{2,39} \text{ (Synder i Schneider, 1991),} \quad (15)$$

$$E = 2,0173 \cdot \rho_{ash}^{2,46} \text{ (Dalstra, 1993),} \quad (16)$$


$$E = 33,9 \cdot \rho_{ash}^{2,20} \text{ (Keyak, 1994),} \quad (17)$$

$$E = 2,875 \cdot \rho_{app}^3 \text{ (Carter i Hayes, 1977),} \quad (18)$$

gdje je E modul elastičnosti u GPa, a ρ_{ash} i ρ_{app} su gustoće kosti u g/cm^3 . Izrazi od (13) do (18) grafički su prikazani na slikama 63. i 64.



Slika 63. Grafički prikaz izraza (13), (15) i (18)



Slika 64. Grafički prikaz izraza (14), (16) i (17)

Spomenute relacije najviše su zastupljene u literaturi, zato što su njihovim korištenjem za definiranje konstitutivnih modela dobivena najmanja odstupanja numeričkih rezultata za deformacije na površini kosti u usporedbi s eksperimentalnim rezultatima. Navedeni izrazi koristit će se i u sklopu ovog istraživanja za definiranje konstitutivnog modela svinjskih, ovčjih i kadaveričnih femura. Važno je istaknuti da spomenuti izrazi vrijede isključivo za elastično područje. Kao što se vidi u izrazima od (13) do (18) neki se baziraju na gustoći

koštanog pepela (ρ_{ash}), a neke na prividnoj gustoći kosti (ρ_{app}). To ponajprije ovisi o metodi mjerenja gustoće kosti i o uvjetima u kojima su provedena eksperimentalna ispitivanja. Izrazi (14) i (18) vrijede za cijelo područje gustoće, dok recimo izrazi (13), (16) i (17) vrijede za područje gustoće do $\rho_{\text{app}} < 1 \text{ g/cm}^3$. Relacija (15) je ograničena na područje povišene gustoće kosti ($1,748 < \rho_{\text{app}} < 1,952 \text{ g/cm}^3$), što se jasno vidi i na slici 62. Zbog toga će se izrazi (13), (15), (16) i (17) ekstrapolirati na cijelo područje gustoće kosti. Vrijednost parametara a i b u izrazima (13) do (18) prikazane su u tablici 9. pri čemu su odvojeno dani modeli kojima je $\rho = \rho_{\text{app}}$ i modeli kojima je $\rho = \rho_{\text{ash}}$.


Tablica 9. Tablični prikaz relacija gustoća – modul elastičnosti kosti

Konstitutivni model $E = a \cdot \rho^b$	(Morgan) $E = a \cdot \rho_{\text{app}}^b$ $a = 6,85$ $b = 1,49$	(Synder i Schneider) $E = a \cdot \rho_{\text{app}}^b$ $a = 3,891$ $b = 2,39$	(Carter i Hayes) $E = a \cdot \rho_{\text{app}}^b$ $a = 2,875$ $b = 3$
Konstitutivni model $E = a \cdot \rho^b$	(Keller) $E = a \cdot \rho_{\text{ash}}^b$ $a = 10,5$ $b = 2,57$	(Dalstra) $E = a \cdot \rho_{\text{ash}}^b$ $a = 2,0173$ $b = 2,46$	(Keyak) $E = a \cdot \rho_{\text{ash}}^b$ $a = 33,9$ $b = 2,20$

6.4.1.3 Preslikavanje parametara materijala na mrežu konačnih elemenata

Niz CT-snimaka može se smatrati trodimenzionalnim skalarnim poljem Hounsfieldova broja koje se spomenutim relacijama transformira u polje gustoće i poslije u polje modula elastičnosti. Kako se pri obradi CT-podataka barata vokselima, sve vrijednosti gustoće i modula elastičnosti temeljene na Hounsfieldovu broju dodjeljuju se na razini voksel. Svaki voksel ima neku vrijednost Hounsfieldova broja, a time i vrijednost gustoće i modula elastičnosti.

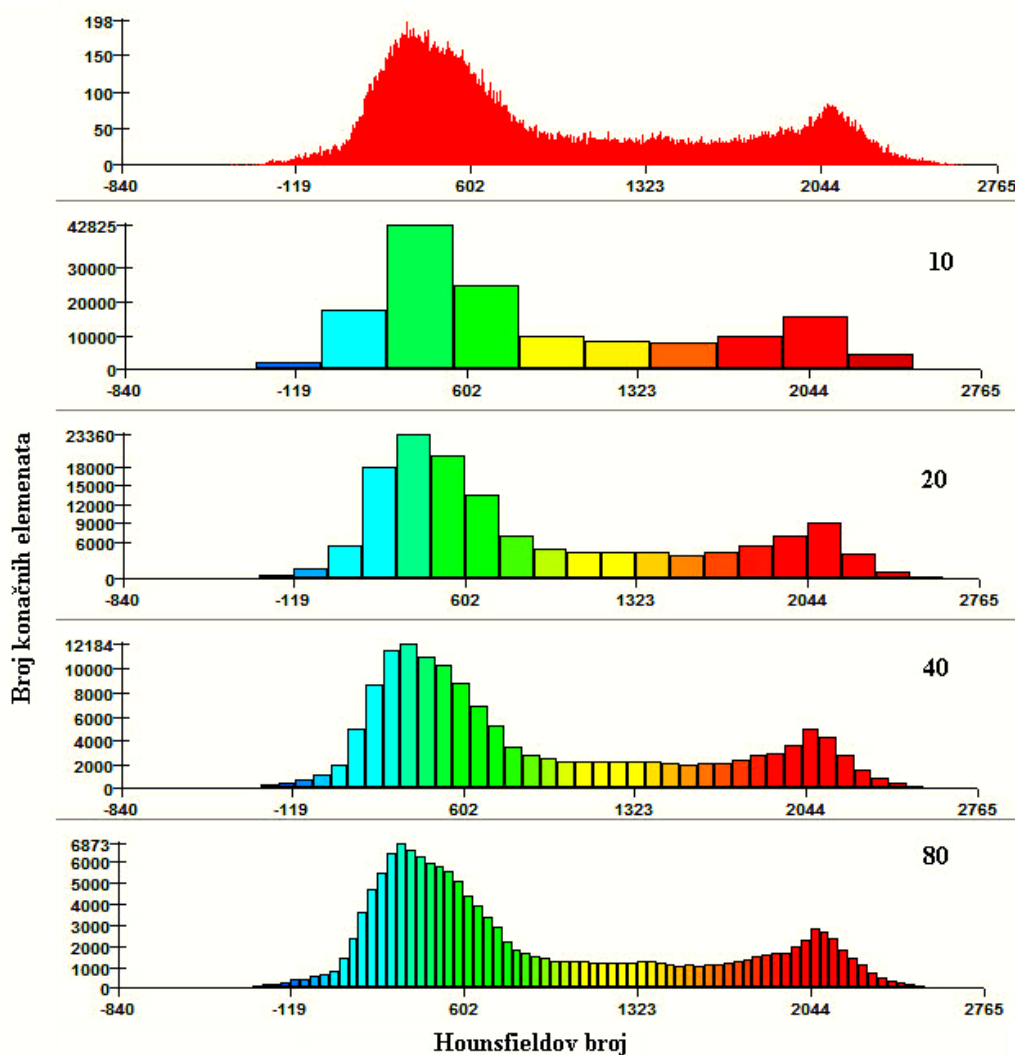
U sljedećem koraku potrebno je te parametre, a uglavnom se misli na modul elastičnosti, preslikati na mrežu konačnih elemenata (slika 65.). Svaki konačni element dobiva individualnu vrijednost modula elastičnosti i tako se modelira nehomogenost kosti.



Slika 65. CT-snimke femura ovce: a) klasični prikaz jednog od CT-slojeva, b) prikaz CT-sloja zajedno s mrežom konačnih elemenata, c) vokseli unutar jednoga konačnog elementa


Nekoliko je metoda preslikavanja parametara materijala na mrežu konačnih elemenata [66, 67, 68]. Jedna od uobičajenih zasniva se na računanju gustoće svakoga pojedinog voksel, te računanju modula elastičnosti svakoga od tih voksel. Budući da se unutar svakog konačnog elementa nalazi nekoliko voksel, svakom konačnom elementu dodjeljuje se srednja vrijednost modula elastičnosti svih voksel unutar tog elementa.

Druga metoda na kojoj se temelji algoritam primijenjen u ovom istraživanju jest da se najprije izračuna srednja vrijednost Hounsfieldova broja svih voksel unutar jednoga konačnog elementa, a zatim gustoća i modul elastičnosti koji se dodjeljuje konačnom elementu. Hounsfieldova skala koja obuhvaća sve voksele unutar mreže konačnih elemenata cijelog modela najprije je podijeljena na konačan broj jednakih segmenata tako da svaki segment poprima jednu HU vrijednost koja se dodjeljuje konačnim elementima (slika 66.). Svakom konačnom elementu dodijeljena je ona HU vrijednost iz segmenta koja je najbliža srednjoj vrijednosti Hounsfieldova broja svih voksel koji su unutar toga konačnog elementa. Iz dodijeljene HU vrijednosti izračunava se gustoća i modul elastičnosti prema prije spomenutim izrazima. Preslikavanje parametara materijala na mrežu konačnih elemenata provedeno je programskim paketom *Mimics*.




Slika 66. Podjele Hounsfieldove skale na konačan broj segmenata kod modela svinjskoga proksimalnog femura

Pojednostavnjeno rečeno, svaki stupac na slici 66. predstavlja jedan *materijal* (modul elastičnosti) koji se dodjeljuje određenom konačnom elementu. Spomenuti postupak podjele Hounsfieldove skale na segmente naziva se homogenizacijom, a provedena je sa stupnjevima 10, 20, 40 i 80, kao što se vidi na slici 66. Ispitivanje stupnja homogenizacije obavljeno je analogno ispitivanju konvergencije rješenja pri definiranju gustoće mreže konačnih elemenata, s razlikom što se ovdje umjesto s brojem konačnih elemenata barata sa stupnjem homogenizacije. Ispitan je utjecaj stupnja homogenizacije Hounsfieldove skale na vršne vrijednosti pomaka i deformacija na modelu svinjskog femura korištenjem nehomogenog materijalnog modela prema *Morganu*. Na osnovi provedenih analiza i dijagrama na slikama 67. i 68. odabran je stupanj homogenizacije 40 koji je korišten u ovom istraživanju kod svih nehomogenih numeričkih modela kostiju.




Slika 67. Dijagram ovisnosti maksimalnog pomaka o stupnju homogenizacije kod modela svinjskog femura



Slika 68. Dijagram ovisnosti maksimalne deformacije o stupnju homogenizacije kod modela svinjskog femura

Raspodjela Hounsfieldova broja na mreži konačnih elemenata za svinjski femur i primjer stupnja homogenizacije 40, nalaze se na slici 69.




Slika 69. Raspodjela Hounsfieldova broja kod modela svinjskoga proksimalnog femura za stupanj homogenizacije 40

Na slici 69. vidi se da najviše konačnih elemenata poprima vrijednosti između 0 i 700 HU, što je logično jer veći dio proksimalnog femura zauzima spongiozna, odnosno trabekularna kost. Crvena boja karakterizira veći Hounsfieldov broj, znači veću gustoću, a samim time i veći modul elastičnosti, što je karakteristično za kortikalnu kost. Područje najmanje gustoće pojavljuje se na vratu femura (slika 69.) i označeno je nijansama plave boje, što je ionako opće poznata kritična zona bedrenih kostiju jer su upravo na njima najčešći lomovi. Unutar kosti nalaze se sitne šupljine u kojima su voda i zrak. Ako su te šupljine manje od vokseli, na tim mjestima mogu se lokalno pojaviti vokseli koji imaju negativnu vrijednost Hounsfieldova broja. Posljedica je da su izračunata gustoća, a poslije i modul elastičnosti negativni, što nema fizikalnog smisla. Ovdje je to riješeno tako da je tim vokselima ručno dodijeljena minimalna pozitivna vrijednost modula elastičnosti izračunata na tom modelu kosti. Kako se to pojavljuje u samo nekoliko vokseli u cijelom modelu, zanemariva je pogreška koja proizlazi iz tih korekcija. Tijekom svih numeričkih analiza Poissonov faktor držan je konstantnim i iznosio je 0,3, što je uobičajena vrijednost korištena u literaturi pri numeričkom modeliranju kosti. [71, 78].

6.5. Opterećenje i rubni uvjeti

Opterećenje i rubni uvjeti dodijeljeni su tako da se što vjernije simulira eksperimentalno ispitivanje prikazano u četvrtom poglavlju. U tu svrhu dodatno je napravljen 3D model valjka koji se vidi na slici 70. To je cijev ispunjena polimeriziranom smjesom PMMA kojoj su dodijeljeni parametri materijala. Smjesa se smatra linearno elastičnim homogenim materijalom s izotropnim svojstvima, pri čemu je modul elastičnosti $E = 3088$ MPa, određen eksperimentalno, a Poissonov faktor preuzet je od proizvođača i iznosi $\nu = 0,3$.



Slika 70. Numerički model svinjskog femura: a) pozicioniranje modela kosti, b) dodjeljivanje opterećenja i rubnih uvjeta

Šupljina u smjesi PMMA izrezana je s pomoću modela kosti kako bi dodirne plohe kosti i smjese bile u idealnom kontaktu. Razmak između vrha glave femura i gornjega ruba cijevi h podešen je tako da odgovara razmaku korištenom tijekom eksperimentalnog ispitivanja (107 mm na svinjskim i ovčjim, a 160 mm na kadaveričnim femurima). Na dodirnim plohama definirana je čvrsta mehanička veza (engl. *Tie*), što znači da su izjednačeni pomaci čvorova konačnih elemenata na dodirnim plohama kosti i smjese. Model je pozicioniran kao i tijekom eksperimenta, odnosno tako da je zakrenut za 7° u odnosu prema vertikali (os kidalice), što se

vidi na slici 70 a). Opterećenje je raspodijeljeno na sferni odsječak glave femura, usmjereno vertikalno prema dolje, što se vidi na slici 70. b). Za svaku grupu kostiju, na osnovi eksperimentalnog ispitivanja, odabrana su dva iznosa opterećenja za koja se sa sigurnošću može reći da ne uzrokuju plastične deformacije. Odabrani iznosi opterećenja za pojedine grupe kostiju nalaze se u tablici 10. Što se tiče rubnih uvjeta, na slici 70. b) vidi se da su na vanjskoj cilindričnoj plohi i na dnu cijevi spriječeni pomaci u smjeru sve tri koordinatne osi, što je u skladu s eksperimentalnim ispitivanjem.

Tablica 10. Iznosi opterećenja za pojedine grupe kostiju

Opterećenje	Svinjski femuri	Ovčji femuri	Kadaverični femuri
1.	1,5 kN	3 kN	3 kN
2.	3 kN	6 kN	6 kN


Navedeni postupak definiranja rubnih uvjeta i opterećenja primijenjen je za sve tri grupe kostiju koje su predmet ovog istraživanja. Svaka kost unutar spomenute tri grupe najprije je numerički modelirana koristeći homogena materijalna svojstva, pri čemu su modul elastičnosti $E = 17$ GPa i Poissonov faktor $\nu = 0,3$ preuzeti iz literature [71]. Nakon toga pristupilo se numeričkom modeliranju upotrebom nehomogenih materijalnih svojstva koja su određena već navedenim postupkom. Sve analize provedene su na računalu *OpenServer M5000* opremljenom dvama procesorima Xeon s po 6 jezgri i radnom memorijom od 64 GB RAM-a.

7. REZULTATI

U ovom poglavlju prikazani su rezultati eksperimentalnog ispitivanja i numeričkog modeliranja kosti. Rezultati nisu prikazani u odvojenim poglavljima jer se ovo istraživanje većim dijelom temelji na usporedbi rezultata eksperimentalnog ispitivanja i numeričkog modeliranja. U prvom dijelu prikazani su rezultati eksperimentalnog ispitivanja dobiveni savijanjem cijelih svinjskih femura u tri točke, a nakon toga slijede rezultati tlačnog opterećivanja svinjskih, ovčjih i kadaveričnih femura.

7.1. Rezultati savijanja svinjskih femura u tri točke

Detaljan opis eksperimentalnog ispitivanja dan je u poglavlju 4.1. Ova grupa kostiju nije numerički modelirana i zato su ovdje prikazani rezultati samo eksperimentalnog ispitivanja. Kako je već ranije navedeno, tijekom ovog ispitivanja opterećenje je narinuto kontrolom pomaka i mjerena je sila koja uzrokuje lom kosti. Pomak prikazan na apscisi u dijagramima (slika 71. i 72.) jest vertikalni hod kidalice.



Slika 71. Dijagram sila – pomak svježih nezamrznutih svinjskih femura


Dijagram na slici 71. prikazuje rezultate za 15 uzoraka koji nisu bili zamrznuti, nego su ispitani neposredno nakon zaprimanja. Svi uzorci ispitani su do loma, a maksimalna sila pri kojoj se dogodio lom na pojedinom uzorku dana je u tablici 11. Na svakom ispitnom uzorku izmjeren je prije ispitivanja najmanji promjer trupa femura, a nakon ispitivanja izmjerena je srednja debljina kortikalnog dijela kosti na mjestu loma.

Tablica 11. Maksimalna postignuta sila i srednja debljina kortikalisa svježih svinjskih femura

Uzorak	Maksimalna sila, N	Najmanji promjer trupa femura, mm	Debljina kortikalisa, mm
1	4509	25,7	3,31
2	3011	23,3	3,42
3	3542	22	3,60
4	4736	22,85	4,29
5	5786	21,67	4,54
6	5773	23,98	5,19
7	4308	27,25	4,30
8	4351	22,98	3,80
9	5308	24,83	4,87
10	6156	25,85	4,33
11	5030	22,65	4,15
12	4777	21,70	4,25
13	4240	24,30	4,18
14	6177	25,3	4,70
15	3079	21,15	3,49
Srednja vrijednost	4718,87	23,70	4,161
SD	1016,20	1,80	0,55

Za svježe kosti srednja vrijednost maksimalne sile iznosi 4718, 87 N (SD 1016,20).

Analogno je ispitano i preostalih 15 uzoraka koji su nakon zaprimanja čuvani zamrznuti 30 dana i odmrznuti su neposredno prije ispitivanja. Rezultati ispitivanja tih uzoraka nalaze se na slici 72. i u tablici 12.



Slika 72. Dijagram sila – pomak odmrznutih svinjskih femura

Tablica 12. Maksimalna postignuta sila i srednja debljina kortikalisa odmrznutih svinjskih femura

Uzorak	Maksimalna sila, N	Najmanji promjer trupa femura, mm	Debljina kortikalisa, mm
16	3974	24,37	4,57
17	4535	21,46	3,83
18	3790	23,48	4,33
19	5545	22,94	4,94
20	4319	23,3	4,49
21	4746	23,69	4,63
22	4865	23,58	5,45
23	3896	24,20	4,43
24	5587	23,51	5,61
25	4829	25,76	4,71
26	4154	23,76	4,44
27	4034	25,8	4,36
28	3588	24,90	4,26

Uzorak	Maksimalna sila, N	Najmanji promjer trupa femura, mm	Debljina kortikalisa, mm
29	4276	24,08	3,82
30	4639	24,15	4,81
Srednja vrijednost	4424,2	23,932	4,58
SD	595,12	1,075	0,49

Kod odmrznutih kostiju srednja vrijednost maksimalne sile iznosi 4424,2 N (SD 595,12), što je približno 6 % manja sila nego kod svježih kostiju. Rezultati ukazuju da nema statistički znatne razlike u maksimalno postignutoj sili između svježih i odmrznutih kostiju. Tu svakako treba uzeti u obzir i utjecaj namještanja ispitnih uzoraka na kidalici jer se, kako kosti nisu iste veličine, ne mogu jednoznačno pozicionirati na uređaju za opterećivanje.

7.2. Rezultati tlačnog ispitivanja femura

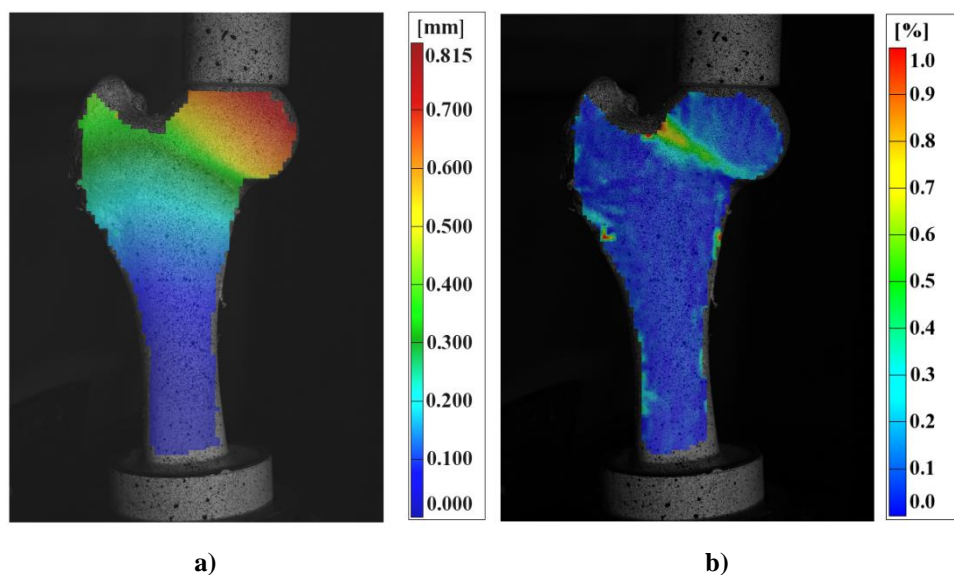
Tlačno ispitivanje femura detaljno je opisano u četvrtom poglavlju gdje su za pojedine grupe kostiju definirani iznosi opterećenja pri kojima su analizirani pomaci i deformacije određene korelacijom digitalne slike. Kako je numerički model opisan u sedmom poglavlju definiran tako da simulira eksperimentalno ispitivanje, rezultati za pomake i deformacije dobiveni metodom konačnih elemenata direktno su uspoređeni s rezultatima dobivenima korelacijom digitalne slike. Pod pomacima se u ovom slučaju smatraju ukupni ekvivalentni pomaci koji ne ovise o izboru koordinatnog sustava, a pod deformacijama se podrazumijevaju maksimalne glavne deformacije čiji iznos također ne ovisi o izboru koordinatnog sustava.

7.2.1. Svinjski femur


Tlačno ispitivanje svinjskih femura detaljno je prikazano u poglavlju 4.2, gdje je definirano opterećenje ekvivalentno silama od 1,5 kN i 3 kN pri kojima se analiziraju pomaci i deformacije određeni korelacijom digitalne slike. Polje pomaka i raspodjela deformacija dobiveni eksperimentalnim ispitivanjem svinjskog femura SF2 prikazani su na slici 73.

Slika 74. prikazuje polje pomaka i raspodjelu deformacija istog uzorka dobivenu metodom konačnih elemenata korištenjem nehomogenoga materijalnog modela prema *Morganu*, uz stupanj homogenizacije 40. Iz rezultata se vidi da se maksimalne vrijednosti pomaka

pojavljaju na glavi femura, što je očekivano s obzirom na narinuto opterećenje, no u tom području se ne pojavljuju značajnije deformacije.




Slika 73. Pomaci i deformacije određeni korelacijom digitalne slike pri sili od 1,5 kN: a) polje pomaka na površini uzorka SF2, b) raspodjela deformacija na površini uzorka SF2



Slika 74. Pomaci i deformacije određeni metodom konačnih elemenata pri sili od 1,5 kN: a) polje pomaka (u mm) na modelu SF2, b) raspodjela deformacija na modelu SF2


Vrat femura mjesto je gdje se očekuju lokalno povišene vrijednosti deformacija, što se vidi i na slici 73. b) koja prikazuje raspodjelu deformacija dobivenu korelacijom digitalne slike. Iz tog razloga je za usporedbu rezultata definiran presjek prikazan na slici 75. duž kojega se analiziraju pomaci i deformacije na svim uzorcima pri spomenutim opterećenjima. Presjek je

definiran tako da može obuhvatiti mehanički odziv cijele kosti, tj. polje pomaka po cijeloj duljini ispitnog uzorka i lokalne deformacije u području vrata femura.




Slika 75. Presjek na SF2 modelu


Rezultati za pomake i deformacije duž presjeka prikazanog na slici 75. dobiveni eksperimentalnim ispitivanjem i numeričkim modeliranjem ispitnog uzorka SF2 prikazani su na slikama 76. – 79. Duljina presjeka, tj. os x na slikama 76. – 79. mjeri se od vrata femura prema distalnom kraju. Slika 76. i slika 77. prikazuju pomake i deformacije pri opterećenju silom od 1,5 kN, a slike 78. i 79. pri opterećenju od 3 kN. Rezultati numeričkog modeliranja prikazani su za slučaj homogenoga i nehomogenoga materijalnog modela. Kao što je navedeno u šestom poglavlju, nehomogeni numerički model homogeniziran je sa stupnjem 40, a zasniva se na izrazima danima u tablici 9.




Slika 76. Pomaci duž presjeka na ispitnom uzorku SF2 pri sili od 1,5 kN



Slika 77. Deformacije duž presjeka na ispitnom uzorku SF2 pri sili od 1,5 kN



Slika 78. Pomaci duž presjeka na ispitnom uzorku SF2 pri sili od 3 kN




Slika 79. Deformacije duž presjeka na ispitnom uzorku SF2 pri sili od 3 kN


Crvena isprekidana linija označava izmjerene pomake (slike 76. i 78.) i deformacije (slike 77. i 79.) po presjeku dobivene metodom DIC tijekom eksperimentalnog ispitivanja. Maksimalne izmjerene deformacije po presjeku uzorka SF2 su 0,83 % pri sili od 1,5 kN i 1,58 % pri sili od 3 kN. Najveći pomak izmjeren na presjeku uzorka SF2 jest 0,42 mm pri sili od 1,5 kN, a pri sili od 3 kN izmjeren je maksimalni pomak od 0,98 mm. Iz prikazanih dijagrama jasno je da homogeni numerički model, označen crtkanom crnom linijom na slikama od 76. do 79., ne

može obuhvatiti lokalne promjene, kao što je naglo povećanje deformacija na vratu femura. Razlika između maksimalnih deformacija izmjerenih DIC-om i dobivenih numeričkim modeliranjem korištenjem homogenog materijalnog modela, vrlo je velika. Približno 14 puta veće deformacije zabilježene su mjerenjem DIC-om, kako pri sili od 1,5 kN, tako i pri sili od 3 kN. Kad je riječ o maksimalnom pomaku na presjeku, tu je razlika manja – približno 33 % manji pomak zabilježen je kod homogenoga numeričkog modela u odnosu prema pomaku izmjenom DIC-om pri sili od 3 kN. Rezultati pokazuju da numerički modeli koji se temelje na nehomogenim materijalnim svojstvima pokazuju bolje poklapanje s eksperimentalno dobivenim pomacima i deformacijama u odnosu prema modelima s homogenim materijalnim svojstvima.

Na primjeru uzorka SF2 vidi se da model prema *Kelleru* pokazuje najbolje poklapanje s eksperimentom. Maksimalna deformacija izračunata po presjeku uzorka SF2 korištenjem *Kellerova* modela iznosi 0,81 % pri sili od 1,5 kN i 1,63 % za sile od 3 kN. Što se tiče maksimalnog pomaka, odstupanje u usporedbi s eksperimentom približno je 12 % pri sili od 1,5 kN i približno 2% pri sili od 3 kN. Maksimalne vrijednosti pomaka i deformacija po presjeku svih svinjskih femura koji su eksperimentalno ispitani i numerički modelirani, dane su dijagramski na slikama 80. do 83.




Slika 80. Maksimalne deformacije po presjeku svinjskih femura pri sili od 1,5 kN




Slika 81. Maksimalni pomaci po presjeku svinjskih femura pri sili od 1,5 kN

Na slikama 80. i 81. maksimalne su vrijednosti pomaka i deformacija po presjeku svinjskih femura pri sili od 1,5 kN.




Slika 82. Maksimalne deformacije po presjeku svinjskih femura pri sili od 3 kN

Na slikama 82 i 83 maksimalne su vrijednosti pomaka i deformacija po presjeku svinjskih femura pri sili od 3 kN.



Slika 83. Maksimalni pomaci po presjeku svinjskih femura pri sili od 3 kN

Iz prikazanih dijagrama na slikama od 80. do 83. vidi se je da numerički model koji ima definirane parametre materijala prema *Kelleru* označen zelenom bojom i daje rezultate najbliže eksperimentu kad je riječ o izračunatim deformacijama, i to kod većine ispitnih uzoraka. Najbolje poklapanje uočeno je kod ispitnog uzorka SF3, gdje je zabilježena relativna pogreška deformacija dobivenih numeričkim modeliranjem u usporedbi s DIC 1,15 % pri sili od 3 kN. Nakon modela prema *Kelleru*, po točnosti izračunatih deformacija u usporedbi s eksperimentom, slijedi numerički model prema *Carteru i Hayesu* koji za ispitni uzorak SF3 odstupa u usporedbi s eksperimentom samo 2 % pri sili od 1,5 kN. Najveće odstupanje svakako pokazuje homogeni numerički model koji za pojedine uzorke daje i do 20 puta manje vrijednosti maksimalnih deformacija u usporedbi s eksperimentom – na slikama 80. i 82. označeno crnom bojom. Što se tiče maksimalnih vrijednosti pomaka po presjeku, rezultati su također neujednačeni. Uočeno je da rezultati za pomake dosta variraju od uzorka do uzorka, tj. da za različite uzorke različiti numerički modeli daju najbolja poklapanja s eksperimentom. Prosječna relativna pogreška maksimalnih deformacija po presjeku svih pet ispitnih uzoraka nalazi se na dijagramu na slici 84.



Slika 84. Prosječna relativna pogreška maksimalnih deformacija svih pet uzoraka svinjskih femura pri sili od 1,5 kN i 3 kN

Vrijednosti na slici 84. apsolutne su kako bi se lakše uočila razlika između rezultata dobivenih korištenjem pojedinih numeričkih modela. Iz rezultata je jasno da najmanju vrijednost prosječne relativne pogreške svih pet ispitnih uzoraka daje nehomogeni numerički model prema *Kelleru*, a pogreška iznosi 10,1 % (SD 8,216) pri sili od 1,5 kN i 10,585 % (SD 12, 49) pri sili od 3 kN.

Kod pomaka najmanju prosječnu pogrešku pokazuje model prema *Morganu* – 9.65 % (SD 6,624) pri sili od 3 kN, no kod deformacija pogreška je 78,25 % (SD 5,59). Rezultati prikazani u ovoj cjelini pokazuju da pri numeričkom modeliranju svinjskog femura korištenjem nehomogenoga numeričkog modela koji se bazira na relacijama gustoća – modul elastičnosti, odabir odgovarajuće relacije iznimno snažno utječe na konačne rezultate za pomake i deformacije. Iz prikazanih rezultata vidi se da će model koji se koristi vezom gustoće i modula elastičnosti prema *Kelleru*, najtočnije prikazati odziv kosti na narinuto opterećenje, što je temelj za eventualnu predikciju loma na osnovi izračunatih deformacija.


Kako su svi ispitni uzorci opterećeni do loma, sila pri kojoj je nastao lom ispitnih uzoraka (F_{max}) i prosječna vrijednost prividne gustoće kosti (ρ_{app}), gustoće koštanog pepela (ρ_{ash}) te radiološke gustoće (ρ_{QCT}), dani su u tablici 13. Prosječna vrijednost gustoće je srednja vrijednost gustoće koja obuhvaća kortikalni i trabekularni dio kosti, a izračunata je na temelju HU-a s pomoću izraza (13) do (18) prikazanih u prethodnom poglavlju.

Tablica 13. Sile loma i prosječne vrijednosti gustoće svinjskih femura


Ispitni uzorak	F_{\max} , N	ρ_{QCT} , g/cm ³	ρ_{ash} , g/cm ³	ρ_{app} , g/cm ³
SF1	5784,25	0,454	0,48	0,79
SF2	5288,75	0,59	0,60	1,00
SF3	5459,45	0,53	0,54	0,90
SF4	7628,75	0,45	0,48	0,79
SF5	6763,12	0,61	0,61	1,02
Srednja vrijednost	6184,864	0,5268	0,542	0,9
SD	988,55	0,07	0,06	0,11

7.2.2. Ovčji femur

Na osnovi dijagrama opterećivanja ovčjih femura prikazanog u poglavlju 4.2., odabrane su sile od 3 kN i 6 kN pri kojima su analizirani pomaci i deformacije. Polje pomaka i raspodjela deformacija pri sili od 6 kN dobiveni eksperimentalnim ispitivanjem uzorka OF2, prikazani su na slici 85, a polje pomaka i raspodjela deformacija istog uzorka dobiveni metodom konačnih elemenata korištenjem nehomogenoga numeričkog modela prema *Morganu*, uz stupanj homogenizacije 40, prikazani su na slici 86.




Slika 85. Pomaci i deformacije određeni korelacijom digitalne slike pri sili od 6 kN: a) polje pomaka na površini uzorka OF2, b) raspodjela deformacija na površini uzorka OF2




Slika 86. Pomaci i deformacije određeni metodom konačnih elemenata pri sili od 6 kN: a) polje pomaka na modelu OF2, b) raspodjela deformacija na modelu OF2

Kako je i ovdje evidentno da se na vratu femura pojavljuju lokalno povišene deformacije, definiran je presjek prikazan na slici 87. na uzorku OF2 analogno kao i za svinjske femure.




Slika 87. Presjek na OF2 modelu


Rezultati za pomake i deformacije duž presjeka za ispitni uzorak OF2, dobiveni numeričkim modeliranjem i eksperimentalnim ispitivanjem, prikazani su slikama 88. do 91. Analogno kao i kod svinjskih femura, rezultati numeričkog modeliranja prikazani su za slučaj homogenog i nehomogenog numeričkog modela, a nehomogeni numerički modeli homogenizirani su sa stupnjem homogenizacije 40.




Slika 88. Pomaci duž presjeka na ispitnom uzorku OF2 pri sili od 3 kN



Slika 89. Deformacije duž presjeka na ispitnom uzorku OF2 pri sili od 3 kN




Slika 90. Pomaci duž presjeka na ispitnom uzorku OF2 pri sili od 6 kN




Slika 91. Deformacije duž presjeka na ispitnom uzorku OF2 pri sili od 6 kN

Iz prikazanih dijagrama na slikama 89. i 91. jasno je da maksimalne izmjerene deformacije po presjeku uzorka OF2 iznose 0,24 % pri sili od 3 kN, odnosno 0,53 % pri sili od 6 kN. Najveći iznos deformacija po prikazanom presjeku pojavljuje se na početku presjeka, tj. u području vrata femura, što je u skladu s mehaničkim ponašanjem svinjskih femura prikazanih u prethodnoj cjelini. Kad je riječ o maksimalnim deformacijama po presjeku, najmanje


odstupanje od eksperimenta ima model čiji su parametri materijala definirani prema *Morganu* – 14 % pri sili od 3 kN, a pri sili od 6 kN odstupanje iznosi 3 %. Iza *Morganova* modela, po točnosti izračunatih deformacija, slijedi model prema *Keyaku* koji pokazuje relativnu pogrešku u usporedbi s metodom DIC od 19 % pri sili od 3 kN i 27 % pri sili od 6 kN. Što se tiče pomaka po presjeku na slikama 88. i 90. vidi se da najviše odstupaju modeli prema *Keyaku* i *Dalstri*, tj. pokazuju najveće odstupanje od pomaka određenih korelacijom digitalne slike. Maksimalne vrijednosti pomaka i deformacija po presjeku svih ovčjih femura koji su eksperimentalno ispitani i numerički modelirani, dane su dijagramski na slikama 92. do 95.




Slika 92. Maksimalne deformacije po presjeku ovčjih femura pri sili od 3 kN



Slika 93. Maksimalni pomaci po presjeku ovčjih femura pri sili od 3 kN




Slika 94. Maksimalne deformacije po presjeku ovčjih femura pri sili od 6 kN



Slika 95. Maksimalni pomaci po presjeku ovčjih femura pri sili od 6 kN

Iz dijagrama na slikama 92. do 95. vidi se da numerički model s parametrima materijala definiranim prema *Morganu*, daje rezultate najbliže eksperimentu kad je riječ o izračunatim deformacijama, i to kod svih ispitnih uzoraka. Najbolje poklapanje uočeno je kod ispitnog uzorka OF4 pri sili od 6 kN (slika 94.), kod kojega relativna pogreška maksimalnih izračunatih deformacija po presjeku u usporedbi s eksperimentom iznosi 1,12 %. Najveće

odstupanje deformacija i pomaka kod svih uzoraka zabilježeno je za numerički model koji ima definirane parametre materijala prema *Dalstri*. Kod pomaka (slika 93. i 95.) najboljima su se pokazali homogeni model s prosječnom relativnom pogreškom u usporedbi s eksperimentom od 11,69 % (SD 10,02) pri sili od 6 kN, te nehomogeni model definiran prema *Morganu* s pogreškom od 9,02 % (SD 7,09) pri sili od 6 kN. Prosječna relativna pogreška maksimalnih deformacija po presjeku svih pet ispitnih uzoraka dana je u dijagramu na slici 96.



Slika 96. Prosječna relativna pogreška maksimalnih deformacija svih pet uzoraka ovčjih femura pri sili od 3 kN i 6 kN

Prema slici 96., najmanju vrijednost prosječne relativne pogreške svih pet ispitnih uzoraka daje nehomogeni numerički model prema *Morganu*, a pogreška iznosi 19,823 % (SD 11,814) pri sili od 3 kN i 5,614 % (SD 5,013) pri sili od 6 kN. Zanimljivo je da se homogeni numerički model po točnosti deformacija nalazi negdje u sredinu. Razlog je taj što ovčji femur ima nešto kraći vrat od svinjskoga i nema toliko izražen prijelaz s trupa na vrat femura te se pojavljuju, iako mjerene pri većim silama, deformacije manjih vrijednosti u odnosu prema deformacijama na svinjskom femuru, što se i pokazalo mjerenjem metodom DIC tijekom eksperimentalnog ispitivanja. Zato većina ispitnih uzoraka ovčjeg femura nije pucala na vratu tijekom eksperimentalnog ispitivanja, nego na trupu. Iz prikazanih rezultata može se zaključiti da se za numeričko modeliranje ovčjih femura svakako treba koristiti nehomogeni numerički model definiran relacijom gustoća – modul elastičnosti prema *Morganu*, jer se pokazao najtočnijim u ovom istraživanju kad je riječ o izračunatim pomacima i deformacijama. Ako je područje interesa samo pomak, odnosno polje pomaka na kosti, rezultati prikazani u ovom poglavlju indiciraju da je korištenje homogenoga numeričkog


modela prihvatljiva alternativa za modeliranje ovčjeg femura. Sile pri kojima je došlo do loma te srednje vrijednosti gustoće ovčjih femura nalaze se u tablici 14.

Tablica 14. Sile loma i prosječne vrijednosti gustoće ovčjih femura


Ispitni uzorak	F_{\max} , N	ρ_{QCT} , g/cm ³	ρ_{ash} , g/cm ³	ρ_{app} , g/cm ³
OF1	7607,5	0,63	0,63	1,06
OF2	7280,2	0,51	0,53	0,88
OF3	8556,9	0,72	0,71	1,19
OF4	7870,7	0,57	0,58	0,97
OF5	7786,35	0,58	0,59	0,98
Srednja vrijednost	7820,33	0,60	0,60	1,016
SD	469,91	0,078	0,067	0,116

7.2.3. Kadaverični femur

Analiza pomaka i deformacija na kadaveričnim femurima provedena je za opterećenja od 3 kN i 6 kN. Analogno, kao i kod prethodnih grupa kostiju, na slici 97. prikazani su rezultati za pomake i deformacije određeni korelacijom digitalne slike na jednom od kadaveričnih ispitnih uzoraka (KF2). Na slici 98. su rezultati nehomogenoga numeričkog modela s parametrima materijala definiranim prema *Kellerovoj* relaciji gustoća – modul elastičnosti. Slike 97 i 98 pokazuju stanje koje odgovara sili od 6 kN.




Slika 97. Pomaci i deformacije određeni korelacijom digitalne slike pri sili od 6 kN: a) polje pomaka na površini uzorka KF2, b) raspodjela deformacija na površini uzorka KF2




Slika 98. Pomaci i deformacije određeni metodom konačnih elemenata pri sili od 6 kN: a) polje pomaka na modelu KF2, b) raspodjela deformacija na modelu KF2


I ovdje, kao i pri numeričkom modeliranju ovčjih i svinjskih femura, korišten je nehomogeni numerički model sa stupnjem homogenizacije 40. Na vratu femura uočene su lokalno povišene vrijednosti deformacija, a rezultati za pomake i deformacije duž presjeka definiranog prema slici 99., prikazani su na slikama 100. i 101. za ispitni uzorak KF2 opterećen silom od 6 kN. Na slici 99. vidi se da presjek nije definiran po cijeloj duljini uzorka zato što tijekom eksperimentalnog ispitivanja kadaveričnih femura cijeli ispitni uzorak nije stao u vidno polje kamere.



Slika 99. Presjek na KF2 modelu



Slika 100. Pomaci duž presjeka na ispitnom uzorku KF2 pri sili od 6 kN




Slika 101. Deformacije duž presjeka na ispitnom uzorku KF2 pri sili od 6 kN

Iz dijagrama na slikama 100. i 101. vidi se da maksimalna vrijednost pomaka i deformacija izmjerenih metodom korelacije digitalne slike iznosi 4,92 mm, odnosno 0,621 %. Izračunati


pomaci numeričkog modela s parametrima materijala prema *Kelleru* (zeleni linija na slici 100.) najbolje prate pomake dobivene eksperimentalnim ispitivanjem.

Također je zanimljivo uočiti da su svi numerički modeli pokazali manje maksimalne vrijednosti pomaka u odnosu na eksperiment, pri čemu homogeni model ima približno dvostruko manju vrijednost maksimalnog pomaka na presjeku u odnosu na eksperiment. Što se tiče deformacija, *Kellerov* model također pokazuje najbolje poklapanje s eksperimentom – relativna pogreška maksimalne deformacije je 6,22 %. Iz slike 101. jasno je da homogeni model ne može ni približno obuhvatiti lokalno povećanje deformacija koje se pojavljuje na početku presjeka, tj. na vratu femura. Relativna pogreška u maksimalnim deformacijama na presjeku homogenog modela u usporedbi s eksperimentom iznosi 92,25 %. Slične su tendencije i na ostalim ispitnim uzorcima, što se vidi iz dijagrama na slikama 102. do 105., koji prikazuju maksimalne vrijednosti pomaka i deformacija na svim kadaveričnim uzorcima koji su eksperimentalno ispitani i numerički modelirani.


Na slikama 102. do 105. usporedba je rezultata za maksimalne pomake i deformacije po presjeku, pri silama od 3 kN i 6 kN. Kako ispitni uzorak KF3 nije postigao silu od 6 kN (lom pri sili od 4,823 kN), rezultati prikazani slikama 104 i 105 rezultati su ispitnih uzoraka KF1 i KF2.



Slika 102. Maksimalne deformacije po presjeku kadaveričnih femura pri sili od 3 kN




Slika 103. Maksimalni pomaci po presjeku kadaveričnih femura pri sili od 3 kN




Slika 104. Maksimalne deformacije po presjeku kadaveričnih femura pri sili od 6 kN

Iz prikazanih rezultata vidi se da kod sile od 3 kN model prema *Carteru i Hayesu* pokazuje najmanju relativnu pogrešku maksimalnih deformacija u usporedbi s eksperimentom, posebice kod uzorka KF3 gdje ta pogreška iznosi samo 0,3 %.



Slika 105. Maksimalni pomaci po presjeku kadaveričnih femura pri sili od 6 kN

Što se tiče pomaka pri sili od 3 kN, na slici 103. vidi se da homogeni model daje približno dvostruko manje maksimalne vrijednosti pomaka u usporedbi s eksperimentom. Pri sili od 6 kN, deformacije ispitnog uzorka KF1 najbolje opisuje *Carterov i Hayesov* model (relativna pogreška u odnosu na eksperiment 5,1 %), a model prema *Kelleru* daje najmanju relativnu pogrešku (6,22 %) za uzorak KF2. Kod pomaka rezultate najbliže eksperimentu daju modeli prema *Dalstri* i prema *Kelleru*. Srednja relativna pogreška maksimalnih deformacija po presjeku kod sile od 3 kN i 6 kN svih triju ispitnih uzoraka dana je u dijagramu na slici 106.



Slika 106. Srednja vrijednost relativne pogreške maksimalnih deformacija uzoraka KF1, KF2 i KF3 pri sili od 3 kN i 6 kN

Iz dijagrama na slici 106. jasno je da je prosječna relativna pogreška numerički izračunatih deformacija s pomoću nehomogenih numeričkog modela u usporedbi s eksperimentom najmanja za slučaj *Carterova* i *Hayesova* modela i iznosi 8,59 % (SD 4,93) pri sili od 6 kN i 5,41 % (SD 4,696) pri sili od 3 kN. Za *Kellerov* model spomenuta relativna pogreška iznosi 10,63 % (SD 6,24) pri sili od 6 kN, a pri sili od 3 kN pogreška iznosi 12,9 % (SD 3,20).

Iz prikazanih rezultata u ovom poglavlju vidi se da homogeni numerički model pokazuje najveće odstupanje u deformacijama, te je zato pri numeričkom modeliranju ljudskog femura nužno korištenje nehomogenih numeričkih modela. Odabir materijalnog modela koji obuhvaća odabir relacije gustoća – modul elastičnosti, ovisi o svrsi i konačnom cilju numeričkog modeliranja. Rezultati prikazani u ovoj cjelini indiciraju da, ako je cilj analiza maksimalnih deformacija i eventualna predikcija loma ljudskog femura, korištenje *Carterova* i *Hayesova* modela daje najpouzdanije rezultate. Ako je cilj globalno promatranje mehaničkog ponašanja kosti, tj. ako se promatraju pomaci i deformacije po cijeloj kosti, rezultati sugeriraju korištenje *Kellerova* modela jer je dobar kompromis zato što za izračunate pomake daje najtočnije rezultate, a po izračunatim deformacijama odmah je iza *Carterova* i *Hayesova* modela. Za kadaverični femur, analogno kao i za svinjske i ovčje femure, sile loma i prosječne vrijednosti gustoće ispitanih nalaze se u tablici 15.

Tablica 15. Sile loma i srednje vrijednosti gustoće kadaveričnih femura

Ispitni uzorak	F_{\max} , N	ρ_{QCT} , g/cm ³	ρ_{ash} , g/cm ³	ρ_{app} , g/cm ³
KF1	6322,55	0,40	0,43	0,73
KF2	6932,45	0,46	0,48	0,80
KF3	4822,65	0,34	0,379	0,63
Srednja vrijednost	6025,88	0,4	0,429667	0,72
SD	1085,736	0,06	0,050501	0,08544

8. ZAKLJUČAK

Svrha ovoga doktorskog rada bila je primijeniti metodu DIC za mjerenje polja pomaka i deformacija na svježim životinjskim i kadaveričnim kostima tijekom *in vitro* eksperimentalnog ispitivanja u svrhu dobivanja što točnijeg mehaničkog odziva kostiju na narinuto opterećenje. Ispitivanja su provedena na svinjskim, ovčjim i kadaveričnim femurima. Za analizu je odabran femur zbog čestih prijeloma kod ljudi. Jedan od ciljeva također je bio spomenutim eksperimentalnim ispitivanjem validirati numeričke modele mehaničkog ponašanja kostiju koji se temelje na nehomogenim numeričkim modelima. Numerički model i geometrija kosti baziraju se na računalnoj tomografiji, pri čemu je najosjetljiviji dio bio pravilan odabir relacije gustoća – modul elastičnosti, koja nije jednoznačna. U literaturi postoji više relacija gustoća – modul elastičnosti, no samo se neke mogu primijeniti za numeričko modeliranje svinjskih i ovčjih kostiju. Stoga je svrha ovoga rada bila na osnovi eksperimentalnog ispitivanja odrediti kojom se relacijom koristiti pri numeričkom modeliranju svinjskih i ovčjih kostiju. Ovčje i svinjske kosti vrlo se često upotrebljavaju u pretkliničkim ispitivanjima stabilnosti ljudskih medicinskih implantata i novih operativnih tehnika, te je zato numeričko modeliranje životinjskih kostiju metodom konačnih elemenata neobično važno.

Kako se govori o svježim kostima, važno je napomenuti da su kosti u provedenom istraživanju prije ispitivanja zamrznute te su tako čuvane do ispitivanja. Stoga je u prvoj fazi ispitivanja utjecaj zamrzavanja kosti na silu loma svinjskog femura kod savijanja u tri točke. Dio ispitnih uzoraka odmah je ispitan nakon zaprimanja, a dio je čuvan zamrznut 30 dana. Rezultati ispitivanja pokazali su da je tijekom ispitivanja 15 uzoraka svježih, ne zamrzvanih kostiju, srednja vrijednost sile loma iznosila 4718,87 N (SD 1016,20). Kod skupine od 15 kostiju koje su čuvane zamrznute, a odmrznute su neposredno prije ispitivanja, srednja vrijednost sile loma iznosila je 4424,2 N (SD 595,12), što je približno 6 % manja sila nego kod svježih kostiju. Budući da su sve životinje iz istoga tova, kosti su im morfološki i po svojstvima vrlo slične. No važno je napomenuti da ispitane kosti ne mogu biti identične, kao što primjerice mogu biti umjetne kosti, te je zato nemoguće identično pozicionirati svaku kost na uređaju za opterećivanje. Isto tako mjesto loma jako varira od kosti do kosti, tako da se iz navedenoga može s velikom sigurnošću zaključiti da zamrzavanje i ponovno odmrzavanje

svježih kostiju nema velik utjecaj na maksimalnu silu loma i na mehanička svojstva kosti, što je u skladu s literaturom [25].

U drugoj fazi istraživanja svinjski, ovčji i kadaverični femuri podvrgnuti su tlačnom opterećenju narinutom na femoralnu glavu, a pomaci i deformacije mjereni su optičkim sustavom *Aramis*. Te iste kosti numerički su modelirane na osnovi CT-snimaka i rezultati za pomake i deformacije uspoređeni su s eksperimentom. Metoda DIC je kao rezultat dala cijelo polje pomaka i deformacija po ispitnom uzorku i obuhvatila je velike gradijente deformacija koje se pojavljuju u blizini vrata, gdje je i najkritičniji dio femura. U tom smislu metoda u kombinaciji s optičkim sustavom *Aramis* iznimno je moćan alat zato što omogućuje da se na osnovi izmjerenih deformacija može vrlo precizno procijeniti mjesto loma kosti. Što se tiče numeričkih modela svinjskih femura, najlošije rezultate za pomake i deformacije daje homogeni numerički model, a najbolje poklapanje s eksperimentom u izračunatim deformacijama pokazuje model prema *Kelleru*. Zanimljivo je da je model prema *Moragnu* najbliže eksperimentu što se tiče pomaka, a u deformacijama pokazuje prosječnu relativnu pogrešku od 78,25 % u usporedbi s eksperimentom. Iz navedenoga se može zaključiti da će pri numeričkom modeliranju svinjskih femura model koji se koristi vezom gustoće i modulom elastičnosti prema *Kelleru*, najtočnije prikazati odziv kosti na narinuto opterećenje i lokalne vrijednosti deformacija, što je temelj za eventualnu predikciju loma na osnovi izračunatih deformacija. Kod ovčjih femura najmanja odstupanja pomaka i deformacija u odnosu prema eksperimentu pokazao je numerički model koji ima relaciju gustoća – modul elastičnosti definiranu prema *Morganu*. Prosječna relativna pogreška izračunatih deformacija u odnosu prema eksperimentu iznosi 5,614 % pri sili od 6 kN. Kod kadaveričnih femura, ako se promatraju samo deformacije, najbolje ih opisuje *Carterov* i *Hayesov* model – prosječna relativna pogreška u odnosu na DIC iznosi 8,59 % (SD 4,93) pri sili od 6 kN i 5,41 % (SD 4,696) pri sili od 3 kN. *Kellerovim* modelom postižu se nešto lošiji rezultati negoli *Carterovim* i *Hayesovim* modelom za deformacije, ali je, kad je riječ o pomaku, pokazao najbolje poklapanje s eksperimentalnim rezultatima.

Kod svih triju grupa kostiju homogeni modeli ne mogu obuhvatiti lokalne promjene, što se tiče deformacija u području vrata femura jer kod nekih modela pokazuju i do 14 puta manje vrijednosti. Pri modeliranju ovčjih femura, korištenje homogenoga numeričkog modela prihvatljiva je alternativa isključivo ako je područje interesa samo polje pomaka. Rezultati ovog istraživanja potvrđuju konstatacije iz literature da pri modeliranju proksimalnog femura, kao nehomogenog materijala, treba biti jako obazriv pri odabiru relacije gustoća – modul elastičnosti. Iako su relacije gustoća – modul elastičnosti u literaturi definirane za ljudski

proksimalni femur, iz prikazanih rezultata jasno je da se određene relacije mogu primijeniti i pri numeričkom modeliranju svinjskih i ovčjih femura, čime je potvrđena hipoteza iz ovoga rada. Vidi se da ista relacija nije prikladna za sve vrste kostiju, što je u skladu s literaturom [66, 67]. Svi numerički modeli definirani u ovom istraživanju kreirani su na isti način, te se može zaključiti da je metodologija kreiranja numeričkog modela ljudskog femura koji se bazira računalnoj tomografiji primjenjiva i za svinjske i ovčje femure. Važno je napomenuti da je numeričkim modeliranjem nemoguće u cijelosti zadovoljiti rubne uvjete i opterećenje koji su definirani tijekom eksperimentalnog ispitivanja, što se najviše vidi po izračunatim pomacima. Također je potrebno istaknuti da se ovdje radi o *in vitro* mehaničkom ispitivanju kojemu nije svrha potpuno oponašati stanje kosti u živom organizmu, nego u laboratorijskim uvjetima izložiti kost nekom karakterističnom opterećenju pri kojemu će izmjerene pomaci i deformacije poslužiti za validaciju numeričkih modela.

8.1. Znanstveni doprinos

Ovim istraživanjem pokazano je da se metoda korelacije digitalne slike može primijeniti za mjerenje polja pomaka i deformacija na površini svježih kostiju podvrgnutih mehaničkom ispitivanju. Polje pomaka i lokalne promjene deformacija na površini ispitnih uzoraka upućuju na to da primjena spomenute metode pridonosi boljem razumijevanju mehaničkog ponašanja kosti i odziva kosti na narinuto opterećenje, što omogućuje pouzdaniju validaciju numeričkih modela mehaničkoga ponašanja kostiju.

S pomoću metode DIC pokazano je koje relacije gustoća – modul elastičnosti, navedene u literaturi, najbolje definiraju parametre materijala za numerički model životinjskih kostiju koji se temelji na računalnoj tomografiji. Na osnovi rezultata ovog istraživanja moći će se, tijekom numeričke analize sustava kost – implantat, pravilnije odabrati relacija gustoća – modul elastičnosti potrebna za definiranje nehomogenih materijalnih svojstava kosti, što će na kraju povećati pouzdanost rezultata računalnih simulacija. Numerički modeli femura koji se baziraju na CT-u pojednostaviti će predoperacijske radnje te će, uz adekvatnu relaciju gustoća - modul elastičnosti, omogućiti pouzdaniju predikciju loma femura, što je jedno od područja budućeg istraživanja.

8.2. Buduća istraživanja

U budućim istraživanjima planira se primjena metode DIC za mjerenje lokalnih deformacija na mjestima potencijalnog loma na osnovi kojih se mogu definirati kriteriji loma za pojedine grupe kostiju. Također je planiran daljnji razvoj nehomogenih numeričkih modela kostiju kako bi se što točnije definirali parametri materijala povezivanjem DIC-a i računalne tomografije (engl. *DVC – Digital Volume Correlation*). To obuhvaća mjerenje pomaka i deformacija po cijelom volumenu ispitnog uzorka, a osiguralo bi precizniju identifikaciju parametara koštanog tkiva.

LITERATURA

1. Sabalić, S. Pločica na zaključavanje za ekstraartikularne prijelome distalnog humerusa - biomehanička studija na osteoporotičnom modelu, doktorski rad, Sveučilište u Osijeku, Osijek, 2012.
2. Sedlin, E. D., A rheological model of cortical bone. *Acta Orthopaedica*. 1965;83:1-77.
3. Burstein, A. H., Reilly, D. T. The ultimate properties of bone tissue: The effect of yieldnig. *Journal of Biomechanics*. 1972;5:35-44.
4. Turner, C.H., Burr, D.B. Basic biomechanical measurements of bone: A Tutorial. *Bone*. 1993;14:595-608.
5. Evans, F. G. Mechanical properties of bone. Springfield, IL: C. C. Thomas. 1973.
6. Dempster, W. T., Liddicoat, R., Compact bone as a non – isotropic material. *The american journal of anatomy*. 1952;91:331-362.
7. Evans, F. G., Lebow, M. Regional differences in some of the physical properties of the human femur. *Journal of applied physiology*. 1951;3:563-572.
8. Pelker, R. R., Friedlaender, G. E., Markham, T. C., Panjabi, M. M., Moen, C. J. Effect of freezing and freez – dryng on the biomechanical properties of rat bone. *Journal of orthopedics*. 1984;1:405-411.
9. Ashman, R. B., Cowin, S. C., Van Buskirk, W. C., Rice, J. C. A continuous wave technique for the measurement of the elastic properties of cortical bone. *Journal of Biomechanics*. 1984;17:349-361.
10. Van Haaren, E. H., van der Zwaard, B. C., van der Veen, A. J., Heyligers, I. C., Wuisman, P.I., and Smit, T.H., Effect of long-term preservation on the mechanical properties of cortical bone in goats, *Acta orthopaedica*. 2008;79:708-716.
11. Carter, D. R.; Hayes, W. C.; Shurman. D. 1. Fatigue life of compact bone - Effects of micmstmcture and density. *Journal of Biomechanics*. 1976;9:211.

12. Pearce, A.I., Richards, R.G., Milz, S., Schneider, E., Pearce, S.G. Animal models for implant biomaterial research in bone: A review. *European Cells and Materials*. 2007;13:1-10.
13. Keyak, J. H., Fourkas, M. G., Meagher, J. M. Skinner, H. B. Validation of an automated method of three-dimensional finite element modelling of bone. *Journal of Biomedical Engineering*. 1993;15(6):505-509.
14. Carter, D. R., Shimaoka, E. E., Harris, W. H., Gates, E. I. Caler, W. E., McCarthy, J. C. Changes in long-bone structural properties during the first 8 weeks of plate implantation. *Journal of Orthopaedic research*. 1984;2(1):80-89.
15. Wang, X., Mabrey, J., Agrawal, C. An interspecies comparison of bone fracture properties *Biomedical Materials And Engineering*. 1998;8:1-9.
16. Opie, L., Bruyneel, K., Lubbe, W. What has the baboon to offer as a model of experimental ischemia *Europ. Heart Journal*. 1983;4:55.
17. An YH, Friedman, J., H. Animal selections in orthopaedic research. In: *Animal Models in Orthopaedic Research*. CRC Press LLC, Boca Raton. 1999:39-57.
18. Buser D, Schenk R K, Steinemann S, Fiorellini J.P, Fox, C. H. Influence of surface characteristics on bone integration of titanium implants. A histomorphometric study in miniature pigs. *Journal of biomedical materials research*. 1991;25:889-902.
19. Pearce, A. I., Richards, R. G., Milz, S., Schneider, E., Pearce, S. G. Animal models for implant biomaterial research in bone: a review. 2007;13:1-10.
20. Mosekilde L., Kragstrup J., Richards A. Compressive strength, ash weight, and volume of vertebral trabecular bone in experimental fluorosis in pigs. *Calcified Tissue International*. 1987;40:318-322.
21. Liebschner M. A. Biomechanical considerations of animal models used in tissue engineering of bone. *Biomaterials*. 2004;25:1697-1714.
22. Den Boer, F. C., Patka, P., Bakker F. C., Wippermann, B. W., van Lingen A, Vink G. Q., Bochuizen K., Haarman, H. J. Models used in tissue engineering of bone. New segmental long bone defect model in sheep: quantitative analysis of healing with dual energy x-ray absorptiometry. *Journal of orthopedic research*. 1999;17:654-660.

23. Pastoureau P., Arlot M., Caulin F., Barlet J., Meunier P., Delmas, P. Effects of oophorectomy on biochemical and histological indices of bone turnover in ewes. *Journal of Bone and Mineral Research*. 1989;4:237.
24. Willie B. M., Bloebaum R. D., Bireley W. R., Bachus K. N., Hofmann A. A. Determining relevance of a weightbearing bovine model for bone ingrowth assessment. *Journal of biomedical materials research*. 2004;69:567-576.
25. Turner A., S. Animal models of osteoporosis - Necessity and limitations. *Cells and materials journal*. 2001;1:66-81.
26. McAlister, G., Moyle, D. Some mechanical properties of goose femoral cortical bone *Journal of Biomechanics*. 1983;16:577-589.
27. Kuhn, I. L., Goldstein, S. A., Choi, K., London, M., Feldkamp, L. A., Mathews, L. S. Comparison of the trabecular and cortical tissue moduli from human iliac crests. *Journal of orthopedic research*. 1989;7:876-884.
28. Bloebaum R. D., Ota D. T., Skedros J. G., Mantas J. P. Comparison of human and canine external femoral morphologies in the context of total hip replacement. *Bio – Medical Materials Research*. 1993;27: 1149-1159.
29. Kieser, D., Waddell, J. N., Kieser, J., Theis, J. C., Swain, M. V. The deer femur – A morphological and biomechanical animal model of the human femur. *Bio – Medical Materials and Engineering*. 2014;24:1693 – 1703.
30. Cristofolini, L., Viceconti, M., Cappello, A., Toni, A. Mechanical validation of whole bone composite femur models. *Journal of Biomechanics*. 1996;29:525-535.
31. Cristofolini, L., Viceconti, M., Mechanical validation of whole bone composite tibia models. *Journal of Biomechanics*. 2000;33:279-288.
32. Reilly, D. T., Burstein, A. H., The elastic and ultimate properties of compact bone tissue. *Journal of Biomechanics*. 1975;8:397 - 405.
33. Currey, J. D., The effect of porosity and mineral content on the Young's modulus of elasticity of compact bone. *Journal of Biomechanics*. 1988;21:131 – 139.
34. Reilly, D. T., Burstein, A. H., The mechanical properties of cortical bone. *Journal of Bone and Joint Surgery - Series A*. 1974;56:1001 – 1022.
35. Jepsen, K. J., Davy, D. T., Comparison of damage accumulation measures in human

- cortical bone. *Journal of Biomechanics*. 1997;30:891 – 894.
36. Lakes, R. S., Katz, J. L., and Sternstein, S. S., Viscoelastic properties of wet cortical bone--I. Torsional and biaxial studies. *Journal of Biomechanics*. 1979;12:657-678.
 37. Lang, S. B., Elastic coefficients of animal bone, *Science*, 165(3890), 287-288, 1969.
 38. Lang, S. B., Ultrasonic Method for Measuring Elastic Coefficients of Bone and Results on Fresh and Dried Bovine Bones, *IEEE Transactions on Biomedical Engineering*. 1970;17:101-105.
 39. Pithioux, M., Lasaygues, P., and Chabrand, P., An alternative ultrasonic method for measuring the elastic properties of cortical bone. *Journal of Biomechanics*. 2002;35:961-968.
 40. Rho, J.-Y., Tsui, T. Y., Pharr, G. M., Elastic properties of human cortical and trabecular lamellar bone measured by nanoindentation. *Biomaterials*. 1997;18:1325 – 1330.
 41. Hoffler, C.E., Moore, K. E., Kozloff, K., Zysset, P. K., Brown, M. B., Goldstein, S. A., Heterogeneity of bone lamellar-level elastic moduli, *Bone*, 2000;26:603-609.
 42. Rho, J. Y., Kuhn-Spearing, L., Zioupos, P., Mechanical properties and the hierarchical structure of bone, *Medical Engineering and Physics*. 1998;20:92-102.
 43. Pope, M. H., Outwater, J. O. Mechanical properties of bone as a function of position and orientation. *Journal of Biomechanics*. 1974;7:61 – 66.
 44. Turner, C. H., Rho, J., Takano, Y., Tsui, T. Y., Pharr, G. M. The elastic properties of trabecular and cortical bone tissues are similar: results from two microscopic measurement techniques. *Journal of Biomechanics*. 1999;32:437 – 441.
 45. Rho, J. Y., Kuhn-Spearing, L., and Zioupos, P., Mechanical properties and the hierarchical structure of bone. *Medical Engineering and Physics*. 1998;20:92 – 102.
 46. Helgason, B. Perilli E., Schileo, E., Taddei, F., Brynjólfsson, S., Viceconti, M. Mathematical relationships between bone density and mechanical properties: A literature review. *Clinical Biomechanics*. 2008;23:135-146.
 47. Dall'Ara, E., Luisier, B., Schmidt, R., Kainberger, F., Zysset, P., Pahr, D. A nonlinear QCT-based finite element model validation study for the human femur tested in two configurations in vitro. *Bone*. 2003;52:27-3.
 48. Eberle, S., Göttliger, M., Augat, P. Individual density–elasticity relationships improve accuracy of subject-specific finite element models of human femurs. *Journal of Biomechanics*. 2013;46:2152-2157.

49. Trabelsi, N., Yosibash, Z., Wutte, C., Augat, P., Eberle, S. Patient-specific finite element analysis of the human femur—A double-blinded biomechanical validation. *Journal of Biomechanics*. 2011;44:1666-1672.
50. Yosibash, Z., Trabelsi, N., Milgrom, C. Reliable simulations of the human proximal femur by high-order finite element analysis validated by experimental observations. *Journal of Biomechanics*. 2007;40:3688-3699.
51. Yoneyama, S., Murasawa, Go. Digital image correlation. *Encyclopedia of Life Support Systems (EOLSS) – Experimental Mechanics*, 2007.
52. Zhang, D., Arola, D.D. Applications of digital image correlation to biological tissues. *Journal of Biomedical Optics*. 2004;9(4):691-699.
53. Luyckx, T., Verstraete, M., De Roo, Karel., De Waele, Wim., Bellemans, J., Victor, Jan. Digital image correlation as a tool for three-dimensional strain analysis in human tendon tissue. *Journal of Experimental Orthopaedics*. 2014;1(7):9.
54. Moerman K. M., Holt C. A., Evans S. L. Simms C. K. Digital image correlation and finite element modelling as a method to determine mechanical properties of human soft tissue in vivo. *Journal of Biomechanics*. 2009;42:1150-1153.
55. Zhang, D., D. Arola, D., Eggerton, C. D. A new fast-search strategy for digital image correlation, *Conf. on Theoretical, Experimental and Computational Mechanics*. 2002.
56. Zhang, D., D. Arola, D., Eggerton, BMES/IEEE Joint Meeting. 2002;1276-1277.
57. Zhang, D., D. Arola, D., Eggerton, C., D. An application of digital image correlation to bovine aorta. *Conf. On Theoretical, Experimental and Computational Mechanics*. 2002.
58. Väänänen, S. P., Yavari, S. A., Weinans, H., Zadpoor, A. A., Jurvelin, J. S., Isaksson, H. Repeatability of digital image correlation for measurement of surface strains in composite long bones. *Journal of Biomechanics*. 2013;46:1928-1932.
59. Grassi, L., Vaananen, S. P., Yavari, A. A., Weinans, H., Jurvelin, S. S., Zadpoor, A. A., Isaksson, H. Experimental validation of finite element model for proximal composite femur using optical measurements. *Journal of Biomechanical Behaviour of Biomedical Materials*. 2013;21:86-94.
60. Yavari, S. A., Van der Stok, J., Weinans, H., Zadpoor, A. A. Full-field strain measurement and fracture analysis of rat femora in compression test. *Journal of Biomechanics*. 2013;46:1282-1292.

61. Ghosh R., Gupta, S., Dickinson, A., Browne M. Verification of the digital image correlation technique for bone surface strain measurements. *Journal of Biomechanics*. 2012;45: Suppl 1:277.
62. Sztefek, P., Vanleene, M., Olsson, R., Collinson, R., Pitsillides, A. A., Shefelbine, S. Using digital image correlation to determine bone surface strains during loading and after adaptation of the mouse tibia. *Journal of Biomechanics*. 2010;43:599-605.
63. R. Huiskes and E.Y.S. Chao, A survey of finite element analysis in Orthopaedic biomechanics: The first decade. *Journal of Biomechanics*. 1983;16:385 – 409.
64. Helgason, B. Perilli E., Schileo, E., Taddei, F., Brynjólfsson, S., Viceconti, M. Mathematical relationships between bone density and mechanical properties: A literature review. *Clinical Biomechanics*. 2008;23:135-146.
65. Rho, J. Y., Hobatho, M. C., Ashman, R. B. Relations of mechanical properties to density and CT numbers in human bone. *Medical Engineering & Physics*. 1995;17(5):347-355.
66. Keller, T., S. Predicting the compressive mechanical behavior of bone. *Journal of Biomechanics*. 1994;9(27):1159-1168.
67. Morgan, E.F., Bayraktar, H.H., Keaveny, T.M. Trabecular bone modulus-density relationships depend on anatomic site. *Journal of Biomechanics*. 2003;36(7):897-904.
68. Eberle, S., Göttliger, M., Augat, P. An investigation to determine if a single validated density–elasticity relationship can be used for subject specific finite element analyses of human long bones. *Medical Engineering & Physics*. 2013;35(7):875-883.
69. Koivumäki, E. M. J., Thevenot, J., Pulkkinen, P., Kuhun, V., Link, T. M., Eckstein, F., Jämsä, T. Ct-based finite element models can be used to estimate experimentally measured failure loads in the proximal femur. *Bone*. 2012;50:824-829.
70. Varghese, B., Short, David., Penmetsa, R., Goswami, T., Hangartner, T. Computed-tomography-based finite-element models of long bones can accurately capture strain response to bending and torsion. *Journal of Biomechanics*. 2011;44:1374 – 1379.
71. Austman, L., R., Milner, J., S., Holdsworth, W., D., Dunning, E., C. The effect of the density - modulus relationship selected to apply material properties in a finite element model of long bone. *Journal of Biomechanics*. 2008;41:3171-3176.
72. Öhman, C., Baleani, M., Perilli, E., Dall'Ara, E., Tassani, S., Baruffaldi, F., Viceconti, M., Mechanical testing of cancellous bone from the femoral head: experimental errors due to offaxis measurements. *Journal of Biomechanics* 2007;40: 2426-2433.

73. Schileo, E., Dall'Ara, E., Taddei, F., Malandrino, A., Schotkamp, T., Baleani, M., Viceconti, M. An accurate estimation of bone density improves the accuracy of subject-specific finite element models. *Journal of Biomechanics*. 2008;41:2483-2491.
74. Mark A.C. Neuert, Rebecca L. Austman, Cynthia E. Dunning. The comparison of density-elastic modulus equations for the distal ulna at multiple forearm positions: A finite element study. *Acta of Bioengineering and Biomechanics*. 2013;15:39-43.
75. Chen, G., Schmutz, B., Epari, D., Rathnayaka, K., Ibrahim, S., Schuetz, M. A., Pearcy, M. J. A new approach for assigning bone material properties from CT images into finite element models. *Journal of Biomechanics*. 2010;43:1011-1015.
76. Peng, L., Bai, J., Zeng, X., Zhou, Y. Comparison of isotropic and orthotropic material property assignments on femoral finite element models under two loading conditions. *Medical Engineering & Physics*. 2006;28:227-233.
77. Baca, V., Horak, Z., Mikulanka, P., Dzupa, V. Comparison of an inhomogeneous orthotropic and isotropic material models used for FE analyses. *Medical Engineering & Physics*. 2008;30:924-930.
78. Wirtz, D., C., Pandorf, T., Portheine, F., Radermacher, K., Schiffers, N., Prescher, A., Weichert, D., Niethard, F., U. Concept and development of an orthotropic FE model of the proximal femur. *Journal of Biomechanics*. 2003;36:289-293.
79. Park, J. B. Hierarchical levels of structure in a human femur. *Biomaterials*. New York: Plenum, 1979.
80. Miškić, B., Ovisnost ultrazvučnih parametara petne kosti u dječjoj dobi o genskim polimorfizmima, Sveučilište u Zagrebu, Zagreb, 2010.
81. Lovrenić – Jugović M. Numeričko i eksperimentalno modeliranje procesa deformiranja kortikalnog koštanog tkiva, doktorski rad, Sveučilište u Zagrebu, Zagreb 2012.
82. Bakić, A. Metoda kaustike u analizi kontaktnih problema kompozitnih materijala, doktorski rad, Zagrebu, Zagreb 2009.
83. Bessho, M., Ohnishi, I., Matsuyana, J., Matsumoto, T., Imai, K., Nakamura, K. Prediction of strength and strain of the proximal femur by a CT – based finite element method. *Journal of Biomechanics*. 2007;40:1745-1753.

84. Fazzini, M., Fazzini, M., Laurent, S., Laurent, D., Laurent, O., Laurent, R. Study of image characteristics on digital image correlation error assessment. *Optics and Lasers in Engineering*. 2009;48:335-339.
85. Rončević, B. Analiza kontaktnog problema sa smanjenjem kontakne površine, doktorski rad, Sveučilište u Rijeci, Rijeka 2012.
86. Aramis User Information – Hardware, GOM mbH, Njemačka 2009.
87. Aramis User Manual – Software, GOM mbH, Njemačka 2009.
88. Krstulovic-Opara, L., Surjak, M., Vesenjaj, M., Tonković, Z., Kodvanj, J., Domazet, Ž. Comparison of infrared and 3D digital image correlation techniques applied for mechanical testing of materials. *Infrared Physics & Technology*, 2015;73:166-174.
89. www.imaginis.com/ct-scan/brief-history-of-ct
90. <http://bctechnical.com/systems/aquilion-16>
91. <http://www.physicscentral.com>
92. Brown, S., Bailey, D. L., Willowson, K., Baldock, C. Investigation of the relationship between linear attenuation coefficients and CT Hounsfield units using radionuclides for spect. *Applied Radiation and Isotopes*. 2008;66:1206-1212.
93. Frković, M., Višković, K. Radiološka oprema, udžbenik, Zdravstveno veleučilište. 2013.
94. Jha A. K., Purandare N. C., Shah S., Agrawal A., Puranik A. D., Rangarajan V. Identification of a unique cause of ring artifact seen in computed tomography trans-axial images. *Indian Journal of Nuclear Medicine*. 2013; 28(4):232-3.
95. Sorić, J., Metoda konačnih elemenata, Zagreb, Golden marketing - Tehnička knjiga, 2004.
96. Ramos, A., Simoes, J. A. Tetrahedral versus hexahedral finite elements in numerical modeling of the proximal femur. *Medical Engineering and Physics*. 2006;28:916-924.

Životopis

Martin Surjak rođen je 3. rujna 1985. godine u Varaždinu. Elektrostrojarsku srednju školu završio je u rodnom gradu 2003. godine. Iste godine upisuje se na Prirodoslovno-matematički fakultet u Zagrebu te godinu dana poslije mijenja fakultet, odnosno upisuje se na Fakultet strojarstva i brodogradnje u Zagrebu. Na drugoj godini opredijelio se za usmjerenje inženjersko modeliranje i računalne simulacije. Godine 2008. završio je preddiplomski dio studija i stekao zvanje sveučilišnog prvostupnika. Godinu dana nakon toga završava diplomski dio studija obranom diplomskoga rada kojemu je tema bila *Numeričko određivanje parametara mehanike loma primjenom tehnike podmodeliranja*, pod mentorstvom prof. dr. sc. Zdenka Tonkovića i asistenta Eduarda Marenića. Od 2010. godine zaposlen je kao asistent u Zavodu za tehničku mehaniku Fakulteta strojarstva i brodogradnje Sveučilišta u Zagrebu. Iste godine upisao je poslijediplomski doktorski studij, smjer *Teorija konstrukcija*. Kao suradnik radio je na znanstvenom projektu *Eksperimentalna simulacija oštećenja mehaničkih i biomehaničkih sustava*, te je kao istraživač sudjelovao u projektu Europske unije IPA IIIC *Centar izvrsnosti za procjenu stanja konstrukcija*. Trenutačno se bavi eksperimentalnim ispitivanjima i numeričkim modeliranjem mehaničkih i biomehaničkih sustava.

Suautor je 11 znanstvenih radova, od kojih je jedan objavljen u renomiranom CC znanstvenom časopisu. U nastavi sudjeluje izvođenjem auditornih i laboratorijskih vježbi iz kolegija: Mehanika I, Mehanika II, Teorija elastičnosti, Eksperimentalna mehanika te Fotogrametrija i vizualizacija objekata. Također sudjeluje u izvođenju auditornih vježbi iz kolegija Mehanika na Hrvatskome vojnom učilištu. Član je Hrvatskoga društva za mehaniku (HDM). Govori engleski i njemački jezik. Oženjen je i otac jednog djeteta.

Curriculum vitae

Martin Surjak was born on September 3, 1985 in Varaždin. He completed the Secondary Technical School in Varaždin in 2003. That same year he enrolled in the Faculty of Natural Sciences and Mathematics in Zagreb, and a year later he transferred to the Faculty of Mechanical Engineering and Naval Architecture, University of Zagreb. In the third semester of his studies he opted for the specialization in engineering modeling and numerical simulations. In 2008 he completed his undergraduate studies and obtained a bachelor's degree. A year later he completed his graduate studies with the graduation thesis titled "Calculating fracture mechanics parameters using submodeling technique" under the supervision of Professor Tonković and assistant Eduard Marenčić. Since 2010 he has been employed as a research assistant at the Department of Engineering Mechanics at the Faculty of Mechanical Engineering and Naval Architecture. He participated in the scientific project "Experimental simulation of failure of mechanical and biomechanical systems" and as a researcher he was also involved in the IPA IIIC project "Centre of Excellence for Structural Health" financed by the European Union. His research currently focuses on experimental studies and numerical modeling of mechanical and biomechanical systems. He is co-author of 11 scientific papers, one of which has been published in a renowned CC scientific journal. He also participates in the teaching activities of the Department performing auditory and laboratory exercises in the courses titled Mechanics I, Mechanics II, Theory of Elasticity, Experimental Mechanics and Photogrammetry and visualization of the objects at the Faculty of Mechanical Engineering and Naval Architecture as well as the auditory exercises in the course of Mechanics at the Croatian Military Academy. He is member of the Croatian Society of Mechanics. He speaks English and German. Married and father of one child.